



TUGAS AKHIR – SS141501

**PEMODELAN PENDAPATAN ASLI DAERAH
DI PROVINSI SUMATERA BARAT MENGGUNAKAN
*FEED FORWARD NEURAL NETWORKS***

**RENI ZUHERLINA
NRP 1315 105 002**

**Dosen Pembimbing
Dr. Kartika Fithriasari, M.Si
Pratnya Paramitha Oktaviana, M.Si, M.Sc**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



TUGAS AKHIR – SS141501

**PEMODELAN PENDAPATAN ASLI DAERAH
DI PROVINSI SUMATERA BARAT MENGGUNAKAN
*FEED FORWARD NEURAL NETWORKS***

**RENI ZUHERLINA
NRP 1315 105 002**

**Dosen Pembimbing
Dr. Kartika Fithriasari, M.Si
Pratnya Paramitha Oktaviana, M.Si, M.Sc**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



FINAL PROJECT – SS141501

**LOCAL GOVERNMENT REVENUE MODELLING
IN THE PROVINCE OF WEST SUMATERA
USING FEED FORWARD NEURAL NETWORKS**

**RENI ZUHERLINA
NRP 1315 105 002**

**Supervisor
Dr. Kartika Fithriasari, M.Si
Pratnya Paramitha Oktaviana, M.Si, M.Sc**

**UNDERGRADUATE PROGRAM
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**

LEMBAR PENGESAHAN

PEMODELAN PENDAPATAN ASLI DAERAH DI PROVINSI SUMATERA BARAT MENGGUNAKAN *FEED FORWARD NEURAL NETWORKS*

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada
Program Studi Sarjana Departemen Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

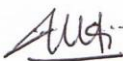
RENI ZUHERLINA
NRP. 1315 105 002

Disetujui oleh Pembimbing:

Dr. Kartika Fithriasari, M.Si
NIP. 19691212 199303 2 002

()

Pratnya Paramitha Oktaviana, M.Si, M.Sc
NIP. 13002014 05 001

()



(Halaman ini sengaja dikosongkan)

PEMODELAN PENDAPATAN ASLI DAERAH DI PROVINSI SUMATERA BARAT MENGGUNAKAN FEED FORWARD NEURAL NETWORKS

Nama Mahasiswa : Reni Zuherlina
NRP : 1315 105 002
Departemen : Statistika
Dosen Pembimbing 1 : Dr. Kartika Fithriasari, M.Si
Dosen Pembimbing 2 : Pratnya Paramitha Oktaviana,
M.Si, M.Sc

Abstrak

Peran pemerintah dalam pembangunan membutuhkan berbagai sarana dan fasilitas pendukung agar terlaksananya pembangunan yang berkesinambungan. Mengoptimalkan penerimaan keuangan daerah dapat mengurangi ketergantungan terhadap pemerintah pusat sehingga dapat mewujudkan kemandirian daerah. Untuk mencapai hal tersebut, diperlukan pengelolaan Pendapatan Asli Daerah (PAD) secara efektif, efisien, serta profesional, dan berkelanjutan. PAD dipengaruhi oleh pengeluaran pemerintah, Produk Domestik Regional Bruto, jumlah penduduk, jumlah perusahaan, jumlah hotel dan jumlah pelanggan listrik. Hasil penerimaan PAD yang selalu berubah sulit untuk memprediksinya, sehingga diperlukan pemilihan metode prediksi yang berguna meminimumkan kesalahan dalam memprediksi. Metode prediksi yang digunakan pada penelitian ini adalah Neural Networks bertujuan untuk memodelkan PAD. Salah satu algoritma Neural Networks adalah Feed Forward Neural Networks. Model Feed Forward Neural Networks terdiri dari lapisan input, hidden, dan output. Model yang optimum di hidden layer sebanyak 1 neuron, dengan model terbentuk adalah FFNN (12,1,1).

Kata kunci: Feed Forward Neural Networks, Pendapatan Asli Daerah.

(Halaman ini sengaja dikosongkan)

LOCAL GOVERNMENT REVENUE MODELLING IN THE PROVINCE OF WEST SUMATERA USING FEED FORWARD NEURAL NETWORKS

Student Name : Reni Zuherlina
Student Number : 1315 105 002
Department : Statistics
Supervisor 1 : Dr. Kartika Fithriasari, M.Si
**Supervisor 2 : Pratnya Paramitha Oktaviana, M.Si,
M.Sc**

Abstract

The role of government in development requires various supporting infrastructures and facilities for the implementation of sustainable development. Optimizing local financial revenue can reduce dependence on the government so as to realize regional self-reliance. In order to achieve that, the effective, efficient, professional, and sustainable Local Government Revenue management is required. Local Government Revenue is affected by government expenditures, Gross Regional Domestic Product, population, number of firms, number of hotels, and number of electricity customers. The frequently changing Local Government Revenue acceptance result is difficult to predict, so it is required to choose the useful prediction methods to minimize errors in predicting. The prediction method used in this research is Neural Networks aims to model PAD. One of Neural Networks algorithms is Feed Forward Neural Networks. Feed Forward Model Neural Networks consists of input, hidden, and output layers. The optimum model in the hidden layer is 1 neuron, with the model obtained is FFNN (12,1,1).

Keywords : Feed Forward Neural Networks, Local Government Revenue

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur Alhamdulillah senantiasa penulis panjatkan kehadiran Allah SWT yang telah melimpahkan rahmat, hidayah dan karunia-Nya sehingga penulis dapat menyelesaikan Tugas Akhir yang berjudul **“Pemodelan Pendapatan Asli Daerah di Provinsi Sumatera Barat Menggunakan *Feed Forward Neural Networks*”** dengan lancar dan tepat waktu.

Keberhasilan penyusunan Tugas Akhir ini tidak lepas dari partisipasi berbagai pihak yang telah banyak membantu. Oleh karena itu, penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Dr. Kartika Fithriasari, M.Si dan Pratnya Paramitha Oktaviana, M.Si, M.Sc selaku dosen pembimbing atas semua bimbingan, waktu, semangat dan perhatian yang telah diberikan sehingga Tugas Akhir ini dapat diselesaikan dengan baik.
2. Prof. Drs. Nur Iriawan, M.Ikom, PhD dan Bambang Wijarnako Otok, S.Si, M.Si selaku tim penguji yang telah memberikan saran dan kritik yang membangun dalam kesempurnaan Tugas Akhir ini.
3. Dr. Suhartono selaku Ketua Departemen Statistika ITS yang telah memberikan fasilitas dalam kelancaran Tugas Akhir ini
4. Dr. Sutikno, M.Si dan Dr. Santi Wulan Purnami, M.Si selaku Ketua Program Studi S1 dan Sekretaris Program Studi S1 yang mengawal proses berjalannya Tugas Akhir Mahasiswa S1 dengan bimbingan serta fasilitas yang diberikan.
5. Haryono, MSIE selaku Dosen Wali penulis, seluruh dosen, dan karyawan Statistika ITS atas ilmu dan pengalaman yang telah diberikan kepada penulis.
6. Ibunda Ernawati serta Ayahanda Zukarnain, atas semangat, kasih sayang dan doa yang tidak pernah putus kepada penulis.

7. Adik-adik tercinta Hazrivo Putra Zurna dan Ulya Putra Kazurna yang tidak pernah berhenti memberi perhatian kepada penulis.
8. Mahasiswa Jurusan Statistika Lintas Jalur Angkatan 2015 atas semangat yang diberikan pada penulis.
9. Semua pihak yang telah membantu penulis yang tidak dapat disebutkan satu persatu.

Semoga kebaikan dan bantuan yang telah diberikan kepada penulis dibalas dengan kebaikan yang lebih oleh Allah SWT. Amin.

Penulis menyadari bahwa Tugas Akhir ini masih terdapat kekurangan, oleh karena itu kritik dan saran yang bersifat membangun sangat diharapkan. Semoga Tugas Akhir ini dapat memberikan manfaat baik bagi penulis, pembaca, dan semua pihak.

Surabaya, Juli 2017
Penulis

Reni Zuherlina

DAFTAR ISI

	Halaman
JUDUL	i
LEMBAR PENGESAHAN	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xv
DAFTAR LAMPIRAN	xvii
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	4
1.3 Tujuan Penelitian	4
1.4 Manfaat Penelitian	4
1.5 Batasan Masalah	5
BAB II TINJAUAN PUSTAKA	
2.1 Pendapatan Asli Daerah	7
2.2 Uji Linieritas	9
2.3 <i>Neural Networks</i>	10
2.4 Fungsi Aktivasi <i>Neural Networks</i>	12
2.5 <i>Feed Forward Neural Networks</i>	13
2.6 Algoritma <i>Backpropagation</i>	14
2.7 Pemilihan Model Terbaik	16
BAB III METODOLOGI PENELITIAN	
3.1 Sumber Data.....	19
3.2 Variabel Penelitian	19
3.3 Struktur Data	20
3.4 Langkah Analisis.....	20
3.5 Diagram Alir	21
BAB IV ANALISIS DATA DAN PEMBAHASAN	
4.1 Deskripsi Pendapatan Asli Daerah (PAD) di Provinsi Sumatera Barat Tahun 2015	23

4.2 Uji Linieritas Data	32
4.3 Pemodelan dan Peramalan Pendapatan Asli Daerah dengan FFNN	33
4.3.1 Kriteria Kebaikan Model pada Data Pendapatan Asli Daerah.....	35
4.3.2 Peramalan Data Pendapatan Asli Daerah ...	49
BAB V KESIMPULAN	
5.1 Kesimpulan	51
5.2 Saran	52
DAFTAR PUSTAKA	53
LAMPIRAN	55

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Kerangka Konsep	8
Gambar 2.2 Arsitektur Algoritma <i>Backpropogation</i>	13
Gambar 3.1 Diagram Alir.....	21
Gambar 4.1 Penyebaran Jumlah Pendapatan Asli Daerah di Provinsi Sumatera Barat (Y)	24
Gambar 4.2 Penyebaran Pengeluaran Pemerintah (X_1)	26
Gambar 4.3 Penyebaran PDRB (X_2)	27
Gambar 4.4 Penyebaran Jumlah Penduduk (X_3)	28
Gambar 4.5 Penyebaran Jumlah Perusahaan (X_4)	29
Gambar 4.6 Penyebaran Jumlah Hotel (X_5)	30
Gambar 4.7 Penyebaran Jumlah Pelanggan Listrik (X_6)	31
Gambar 4.8 <i>Scatter Plot</i> Data Pendapatan Asli Daerah terhadap faktor yang diduga berpengaruh	32
Gambar 4.9 Arsitektur Jaringan FFNN dengan 1 neuron <i>Hidden Layer</i>	35
Gambar 4.10 Arsitektur Jaringan FFNN 1 Neuron	36
Gambar 4.11 Arsitektur Jaringan FFNN 2 Neuron	37
Gambar 4.12 Arsitektur Jaringan FFNN 3 Neuron	39
Gambar 4.13 Arsitektur Jaringan FFNN 4 Neuron	40
Gambar 4.14 Arsitektur Jaringan FFNN 5 Neuron	41
Gambar 4.15 Arsitektur Jaringan FFNN 6 Neuron	42
Gambar 4.16 Arsitektur Jaringan FFNN 7 Neuron	43
Gambar 4.17 Arsitektur Jaringan FFNN 8 Neuron	45
Gambar 4.18 Arsitektur Jaringan FFNN 9 Neuron	46
Gambar 4.19 Arsitektur Jaringan FFNN 10 Neuron	47
Gambar 4.20 Arsitektur Jaringan FFNN Terbaik	48
Gambar 4.21 Perbandingan Data Aktual dengan Data Ramalan <i>Training</i> dan <i>Testing</i>	49

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

	Halaman
Tabel 3.1 Variabel Respon dan Prediktor dalam Penelitian..	19
Tabel 3.2 Struktur Data	20
Tabel 4.1 Statistika Deskriptif Variabel Penelitian	23
Tabel 4.2 Struktur Data dengan Penambahan Lag 1	34
Tabel 4.3 Uji Kebaikan Model dengan 1 Neuron	36
Tabel 4.4 Uji Kebaikan Model dengan 2 Neuron	37
Tabel 4.5 Uji Kebaikan Model dengan 3 Neuron	38
Tabel 4.6 Uji Kebaikan Model dengan 4 Neuron	39
Tabel 4.7 Uji Kebaikan Model dengan 5 Neuron	40
Tabel 4.8 Uji Kebaikan Model dengan 6 Neuron	42
Tabel 4.9 Uji Kebaikan Model dengan 7 Neuron	43
Tabel 4.10 Uji Kebaikan Model dengan 8 Neuron	45
Tabel 4.11 Uji Kebaikan Model dengan 9 Neuron	46
Tabel 4.12 Uji Kebaikan Model dengan 10 Neuron	47
Tabel 4.13 Pemilihan Model Terbaik pada Data <i>Training</i> dan <i>Testing</i>	48
Tabel 4.14 Peramalan Data Pendapatan Asli Daerah dengan FFNN	49

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

	Halaman
Lampiran 1. Data Penelitian	55
Lampiran 2. Syntax FFNN data <i>Training</i> dengan 1 Neuron di <i>Hidden Layer</i>	58
Lampiran 3. Syntax FFNN data <i>Testing</i> dengan 1 Neuron di <i>Hidden Layer</i>	59
Lampiran 4 Uji Kebaikan Model NN	60
Lampiran 5 Estimasi Parameter Model NN dengan 1 Neuron di <i>Hidden Layer</i>	61

(Halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Otonomi daerah adalah hak, wewenang, dan kewajiban daerah otonom untuk mengatur dan mengurus sendiri urusan pemerintahan dan kepentingan masyarakat setempat sesuai dengan perundang-undangan (UU No. 32, Tahun 2004). Keberhasilan otonomi daerah dapat dilihat dari kemandirian daerah dan kemampuan mengoptimalkan potensi yang ada di daerahnya. Salah satunya dapat dilihat dari Pendapatan Asli Daerah (PAD). PAD merupakan semua penerimaan yang diperoleh dari hasil potensi daerah yang dipungut berdasarkan peraturan daerah sesuai dengan peraturan perundang-undangan, sehingga PAD dapat meningkatkan kesejahteraan rakyat melalui program-program yang dilaksanakan pemerintah.

PAD bersumber dari pajak daerah, retribusi daerah, hasil perusahaan milik daerah dan hasil pengelolaan kekayaan daerah lainnya yang dipisahkan, dan lain-lain merupakan pendapatan asli daerah yang sah (UU Nomor 33, Tahun 2004). Apabila pemerintah dapat menggali potensi daerah maka PAD di daerah tersebut dapat optimal. Sebaliknya, apabila pemerintah tidak dapat menggali potensi daerah, maka PAD pada daerah tersebut tidak optimal yang menyebabkan pemerintah daerah memiliki ketergantungan yang tinggi terhadap pemerintah pusat.

Peran pemerintah dalam pembangunan membutuhkan berbagai sarana dan fasilitas pendukung, termasuk anggaran belanja dalam rangka terlaksananya pembangunan yang berkesinambungan. Untuk mencapai hal tersebut maka diperlukan pengelolaan PAD secara efektif, efisien, serta professional, dan berkelanjutan. PAD dipengaruhi oleh pengeluaran pemerintah, Produk Domestik Regional Bruto (PDRB), dan jumlah penduduk (Santosa dan Rahayu dalam Atmaja, 2011). Pengeluaran tersebut sebagian untuk administrasi pembangunan dan sebagian lain untuk kegiatan pembangunan di berbagai jenis infrastruktur yang

penting. Pembelanjaan daerah meningkatkan pengeluaran agregat dan kegiatan ekonomi. Dengan meningkatnya kegiatan ekonomi, maka aliran penerimaan pemerintah melalui PAD juga meningkat.

Perkembangan PAD di Indonesia setiap tahun selalu meningkat, pada tahun 2014 sebesar 233.277.409 juta sedangkan tahun 2015 sebesar 264.056.790 juta. Sumatera Barat merupakan sepuluh provinsi yang memiliki PAD terendah di Indonesia, namun PAD setiap tahun selalu meningkat. Provinsi Sumatera Barat juga merupakan salah satu provinsi yang kaya keindahan alamnya. Dengan potensi daerah yang tinggi diharapkan provinsi tersebut memiliki PAD yang tinggi pula. PAD Provinsi Sumatera Barat tahun 2014 sebesar 3.635.838 juta meningkat pada tahun 2015 sebesar 3.952.164 juta. Dengan meningkatnya PAD dapat menurunkan angka kemiskinan, angka pengangguran, dan meningkatkan Produk Domestik Regional Bruto (PDRB) di Provinsi Sumatera Barat.

Berdasarkan uraian tersebut seharusnya pencapaian realisasi PAD di Provinsi Sumatera Barat menjadi sebuah prestasi. Namun, proporsi PAD masih relatif kecil (Sholeh dan Rochmansjah, 2010). Hal ini disebabkan karena sumber penerimaan daerah dalam konteks otonomi untuk saat ini masih didominasi oleh bantuan dan sumbangan dari pemerintah pusat. Masalah tersebut yang mendasari untuk dilakukan penelitian lebih lanjut mengenai PAD di Provinsi Sumatera Barat. Meningkatnya PAD setiap tahun perlu diprediksi, prediksi merupakan suatu bagian yang dipertimbangkan untuk membuat perencanaan. Salah satu aspek penting dari perencanaan adalah pembuatan keputusan, proses pengembangan dan penyeleksian sekumpulan kegiatan-kegiatan untuk memecahkan masalah.

Tujuan perencanaan adalah melihat bahwa program-program yang telah dilaksanakan dapat digunakan untuk meningkatkan pembuatan keputusan yang baik. Hasil penerimaan PAD yang selalu berubah mengakibatkan kesulitan untuk memprediksinya, untuk itu diperlukan pemilihan metode prediksi yang berguna

untuk meminimumkan kesalahan dalam memprediksi, sehingga hasil prediksi dapat mendekati kenyataan. Metode prediksi yang digunakan pada penelitian ini yaitu metode Jaringan saraf tiruan yang biasanya disebut dengan *Neural Networks* (NN).

NN merupakan suatu pemrosesan informasi menggunakan karakteristik-karakteristik performa yang mirip dengan proses penyampaian impuls saraf manusia. Model matematis dari suatu masalah sangat sukar untuk dibuat, seperti model perubahan jumlah variabel PAD yang tidak menentu sehingga model NN menyaring informasi tersebut melalui proses pelatihan. Oleh karena itu, metode NN merupakan metode yang tepat untuk menyelesaikan masalah prediksi PAD. Salah satu algoritma NN yaitu *Feed Forward Neural Networks* (FFNN). Model FFNN terdiri dari lapisan *input*, lapisan *hidden*, dan lapisan *ouput*.

Penelitian menggunakan NN telah dilakukan sebelumnya mengenai peramalan curah hujan menggunakan FFNN di banyuwangi dengan hasil penelitian model terbaik yang terpilih adalah model FFNN (33,1) karena memiliki nilai RMSE *out sample* model FFNN lebih kecil dibandingkan dengan RMSE *out sample* pada model *hybrid* (Susanto, 2016). Penelitian sebelumnya juga telah dilakukan mengenai pemodelan produksi minyak dan gas bumi pada platform “MK” di PT X menggunakan metode ARIMA, NN dan *hybrid* ARIMA-NN dengan hasil penelitian bahwa metode NN merupakan metode yang terbaik dalam memodelkan data tersebut (Prameswari, 2016).

Penelitian mengenai analisis faktor-faktor yang mempengaruhi PAD pernah dilakukan menggunakan *Ordinary Least Square* (OLS) di Kota Semarang dengan hasil penelitian menyebutkan pengeluaran pemerintah, PDRB dan jumlah penduduk berpengaruh signifikan terhadap PAD (Atmaja, 2011). Selanjutnya analisis beberapa faktor yang mempengaruhi PAD di Kota Surabaya dengan hasil penelitian jumlah pelanggan listrik berpengaruh nyata terhadap PAD, sedangkan jumlah perusahaan, tingkat inflasi, dan jumlah hotel tidak berpengaruh nyata terhadap PAD karena pemerintah belum sepenuhnya menjalankan

kebijakan agar kondisi perekonomian bisa stabil dan proses perijinan yang tidak rumit sehingga para investor dapat menanamkan modalnya di Kota Surabaya (Muchtholifah, 2010).

Penelitian mengenai prediksi jumlah PAD pernah dilakukan sebelumnya dengan menggunakan metode jaringan saraf tiruan *backpropogation* dengan hasil penelitian dari data parameter tahun 2011 sampai 2012 dan target data 2013 menghasilkan prediksi 143,85792 dengan data target 149 (Adinugraha, 2016). Berdasarkan dari permasalahan tersebut penelitian ini penting dilakukan untuk mengetahui model prediksi Pendapatan Asli Daerah (PAD) di Provinsi Sumatera Barat menggunakan *Feed Forward Neural Networks* (FFNN).

1.2 Rumusan Masalah

Berdasarkan latar belakang, maka rumusan masalah dalam penelitian ini adalah

1. Bagaimana karakteristik PAD di Provinsi Sumatera Barat dan faktor-faktor yang diduga mempengaruhinya pada tahun 2015?
2. Bagaimana model prediksi FFNN mengenai PAD di Provinsi Sumatera Barat?

1.3 Tujuan Penelitian

Tujuan penelitian yang ingin dicapai dalam penelitian ini adalah

1. Menentukan karakteristik PAD di Provinsi Sumatera Barat dan faktor-faktor yang diduga mempengaruhinya pada tahun 2015.
2. Memodelkan prediksi FFNN mengenai PAD di Provinsi Sumatera Barat.

1.4 Manfaat Penelitian

Adapun manfaat yang ingin dicapai dari hasil penelitian ini adalah.

1. Memberikan pengetahuan dan pemahaman mengenai PAD dan dapat menambah pengetahuan keilmuan statistika mengenai metode FFNN.
2. Sebagai salah satu alat pengambil keputusan dalam menentukan anggaran daerah pemerintah Provinsi Sumatera Barat.

1.5 Batasan Masalah

Penelitian ini dibatasi dengan menggunakan sepuluh neuron di *hidden layer*, dan memodelkan prediksi jumlah PAD di Provinsi Sumatera Barat.

(Halaman ini sengaja dikosongkan)

BAB II

TINJAUAN PUSTAKA

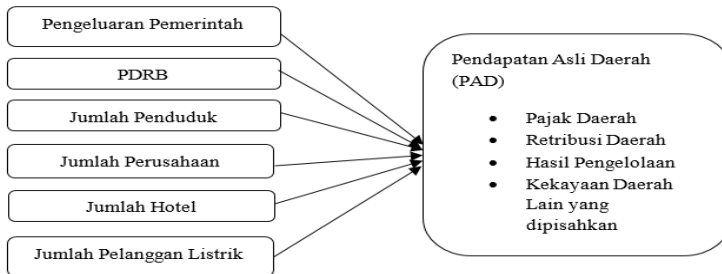
Pada bab ini diuraikan mengenai konsep landasan teori yang digunakan untuk mencapai tujuan penelitian, yaitu mendapatkan model prediksi mengenai pendapatan asli daerah di Provinsi Sumatera Barat menggunakan FFNN. Adapun landasan teori yang digunakan dijelaskan sebagai berikut.

2.1 Pendapatan Asli Daerah (PAD)

Pendapatan Asli Daerah (PAD) merupakan semua penerimaan yang diperoleh dari sumber-sumber dalam wilayahnya sendiri yang dipungut berdasarkan peraturan daerah sesuai dengan peraturan perundang-undangan yang berlaku (Halim, 2004). Sumber PAD terdiri dari pajak daerah, retribusi daerah, hasil pengelolaan kekayaan daerah lainnya yang dipisahkan, dan lain-lain pendapatan asli daerah yang sah (UU Nomor 33, Tahun 2004).

Berdasarkan UU Nomor 28 Tahun 2009 pajak daerah terbagi atas pajak hotel, restoran, hiburan, reklame, penerangan jalan, mineral bukan logam dan bantuan, parkir, tanah, sarang burung walet, bumi dan bangunan perdesaan dan perkotaan dan kendaraan bermotor, bea perolehan hak atas tanah dan bangunan. Menurut UU Nomor 28 Tahun 2009 secara keseluruhan terdapat 30 jenis retribusi yang dapat dipungut oleh daerah yang dikelompokkan ke dalam 3 golongan retribusi, yaitu retribusi jasa umum, retribusi jasa usaha, dan retribusi perizinan tertentu. Menurut UU Nomor 33 Tahun 2004 hasil pengelolaan kekayaan milik daerah lain yang dipisahkan dirinci menurut objek pendapatan yang mencakup bagian laba atas penyertaan modal pada perusahaan milik daerah/BUMD, bagian laba atas penyertaan modal pada perusahaan milik negara/BUMN dan bagian laba atas penyertaan modal pada perusahaan swasta maupun kelompok masyarakat. Pendapatan asli daerah yang sah yaitu hasil penjualan kekayaan daerah yang tidak dipisahkan, jasa

giro, pendapatan bunga, keuntungan dari nilai tukar rupiah terhadap mata uang asing, dan komisi, potongan, ataupun bentuk lain sebagai akibat dari penjualan, pengadaan barang ataupun jasa oleh pemerintah (UU Nomor 33, Tahun 2004). Kerangka konsep dari variabel yang mempengaruhi PAD berdasarkan UU Nomor 33 Tahun 2004 dan penelitian sebelumnya disajikan pada Gambar 2.1.



Gambar 2.1. Kerangka Konsep

Variabel yang mempengaruhi PAD adalah sebagai berikut.

1. **Pengeluaran Pemerintah**

Pelaksanaan pembangunan daerah merupakan program yang memerlukan keterlibatan segenap unsur lapisan masyarakat. Peran pemerintah dalam pembangunan adalah sebagai katalisator dan fasilitator tentu membutuhkan berbagai sarana dan fasilitas pendukung, termasuk anggaran belanja dalam rangka terlaksana-nya pembangunan yang berkesinambungan. Perbelanjaan-perbelanjaan akan meningkatkan pengeluaran agregat dan mempertinggi tingkat kegiatan ekonomi meningkat (Santosa dan Rahayu dalam Atmaja, 2011).

2. **PDRB (Produk Domestik Regional Bruto)**

Meningkatnya PDRB maka akan menambah penerimaan pemerintah daerah untuk membiayai program-program pembangunan. Selanjutnya akan mendorong peningkatan pelayanan pemerintah daerah kepada masyarakat yang

diharapkan akan dapat meningkatkan produktivitasnya meningkat (Santosa dan Rahayu dalam Atmaja, 2011).

3. Jumlah Penduduk

Penambahan jumlah penduduk yang tinggi diiringi dengan perubahan teknologi mendorong tabungan dan juga penggunaan skala ekonomi di dalam produksi. Besarnya pendapatan dapat dipengaruhi oleh penduduk, jika jumlah penduduk meningkat maka pendapatan yang dapat ditarik juga meningkat (Santosa dan Rahayu dalam Atmaja, 2011).

4. Jumlah Perusahaan

Banyaknya perusahaan pada suatu daerah berdampak pada bidang sektor PDRB, dengan meningkatnya PDRB penerimaan keuangan daerah juga bertambah (Muchtolifah, 2010).

5. Jumlah Hotel

Banyaknya hotel suatu daerah berdampak pada bidang sektor PDRB, dengan meningkatnya PDRB penerimaan keuangan daerah juga bertambah (Muchtolifah, 2010).

6. Pelanggan Listrik

Dengan bertambahnya jumlah penduduk, konsumsi listrik disetiap daerah juga meningkat. Sehingga pendapatan yang dapat ditarik pemerintah juga meningkat (Muchtolifah, 2010).

2.2 Uji Linieritas

Pengujian ini digunakan untuk mengetahui apakah antara variabel respon dan variabel prediktor memiliki hubungan linier atau tidak. Uji linieritas pada penelitian ini bertujuan untuk memilih fungsi aktivasi. Salah satu pengujian linieritas adalah uji Terasvirta. Uji Terasvirta termasuk dalam kelompok uji tipe *Lagrange Multiplier*. Hipotesis dalam melakukan uji Terasvirta dengan statistik uji F sebagai berikut (Terasvirta, Lin, dan Granger, 1993).

$H_0 : f(x)$ adalah fungsi linier dalam x atau model linier

$H_1 : g(x)$ adalah fungsi nonlinier dalam x atau model nonlinier

Prosedur untuk memperoleh statistik uji F sebagai berikut.

1. Regresikan Y_t pada X_1, X_2, \dots, X_p kemudian diperoleh residual \hat{u}_t serta hitung jumlah kuadrat residual yaitu $SSR_0 = \sum \hat{u}_t^2$
2. Regresikan \hat{u}_t pada X_1, X_2, \dots, X_p dan m prediktor tambahan, kemudian diperoleh residual \hat{v}_t dan hitung jumlah kuadrat residual yaitu $SSR_1 = \sum \hat{v}_t^2$
3. Menghitung nilai statistik uji F

$$F_{hitung} = \frac{(SSR_0 - SSR_1)/m}{SSR_1/(n - 1 - p - m)} \quad (2.1)$$

dimana:

m : jumlah prediktor tambahan

n : banyak pengamatan

p : jumlah prediktor pada regresi awal

Keputusan : Tolak H_0 , jika $F_{hitung} > F_{tabel}$ dengan derajat bebas m dan $(n - 1 - p - m)$.

2.3 Neural Networks

Neural Networks (NN) adalah suatu pemrosesan informasi menggunakan karakteristik-karakteristik performa yang mirip dengan proses penyampaian impuls saraf manusia. Unsur-unsur dalam NN bekerja secara paralel. Jaringan ini dapat ditentukan dengan hubungan antar unsur-unsurnya untuk mencapai target tertentu. NN dapat diaplikasikan di berbagai bidang terutama pada analisis kompleks yang memiliki masalah nonlinear.

Pada NN, neuron-neuron dikumpulkan dalam lapisan-lapisan (layer) yang disebut neuron layer. Pada umumnya, NN mempunyai tiga macam lapisan, yaitu (Puspitaningrum, 2006)

1. Lapisan *Input* (*input layer*)
Node-node dalam lapisan *input* disebut neuron-neuron *input*. Neuron-neuron *input* menerima *input* berupa gambaran suatu permasalahan dari luar.
2. Lapisan Tersembunyi (*hidden layer*)
Node-node di lapisan tersembunyi disebut neuron-neuron tersembunyi.

3. Lapisan *Ouput* (*ouput layer*)

Node-node di lapisan *output* disebut neuron-neuron *ouput*. Keluaran dari lapisan ini merupakan hasil dari NN terhadap suatu permasalahan.

Karakteristik NN adalah memiliki arsitektur yang merupakan koneksi antar node. Dimana dibutuhkan suatu fungsi aktivasi yang merupakan metode penentuan pembobot antar koneksi dan biasa disebut dengan *training* atau pembelajaran. Algoritma pembelajaran merupakan tahap penyesuaian terhadap bobot yang telah terbentuk secara random. NN memperoleh nilai bobot dari suatu algoritma pembelajaran tertentu. Bobot ini dilakukan dalam melakukan transformasi dari node *input* ke node *output*. Salah satu transformasi data adalah *normalized*. Rumus *normalized* adalah (Dodge, 2003).

$$x' = \frac{(x - \min(x))}{(\max(x) - \min(x))} \quad (2.2)$$

Secara keseluruhan, pemodelan menggunakan NN adalah sebagai berikut.

1. Penentuan pembobot awal

Pembobot awal yang digunakan adalah pembobot awal pada koneksi antar *layer input* dan *layer hidden* (*layer* ke-1) serta antara *layer hidden* (*layer* ke-2) dan *layer output*.

2. *Training* NN

Model NN di *training* pada suatu nilai *epoch* dan dilakukan penilaian terhadap *learning rate* untuk mendapatkan nilai ketepatan prediksi yang tinggi.

3. Pengujian model NN

Testing atau pengujian dilakukan dengan menggunakan data *testing* yang merupakan pasangan dari data *training* yang digunakan untuk mencari pembobot model NN. Langkah selanjutnya adalah melakukan pengukuran terhadap ketepatan model.

2.4 Fungsi Aktivasi *Neural Networks*

Fungsi aktivasi merupakan fungsi yang menggambarkan hubungan antara tingkat aktivasi internal yang mungkin berbentuk fungsi linier ataupun nonlinier. Karakteristik yang harus dimiliki fungsi aktivasi adalah kontinu, diferensiabel, dan tidak menurun secara monoton. Fungsi aktivasi diharapkan jenuh yaitu mendekati nilai-nilai maksimum dan minimum secara asimtot. Macam fungsi aktivasi adalah sebagai berikut (Puspitaningrum, 2006).

1. Fungsi Aktivasi Sigmoid Biner

Fungsi ini merupakan fungsi yang paling umum digunakan. Range pada fungsi ini terletak pada interval 0 sampai 1, fungsi ini dapat dirumuskan sebagai berikut.

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.3)$$

2. Fungsi Aktivasi Sigmoid Bipolar

Fungsi sigmoid bipolar merupakan fungsi yang paling umum digunakan dan memiliki bentuk yang mirip dengan sigmoid biner namun dengan range yang berbeda antara -1 sampai 1. Fungsi sigmoid bipolar dapat dirumuskan sebagai berikut.

$$f(x) = \frac{2}{1+e^{-x}} - 1 \quad (2.4)$$

3. Fungsi Aktivasi Tangen Hiperbolik

Fungsi tangen hiperbolik memiliki range yang sama dengan fungsi sigmoid bipolar yaitu antara -1 sampai 1. Fungsi tangen hiperbolik dapat dirumuskan sebagai berikut.

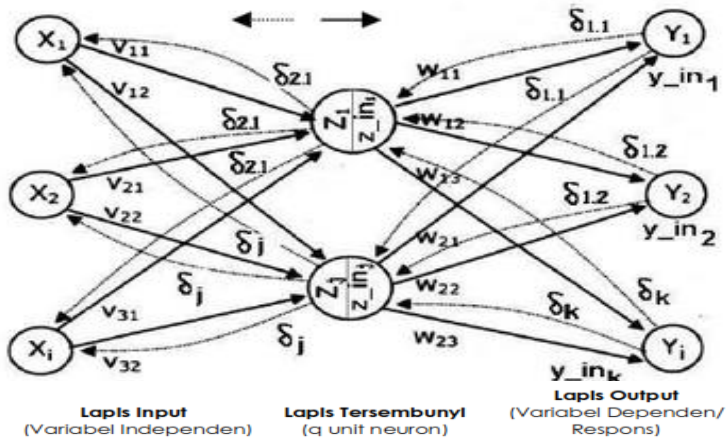
$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \text{ atau } f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (2.5)$$

Untuk jaringan yang *multilayer*, fungsi aktivasi yang digunakan adalah fungsi aktivasi nonlinier, jika digunakan fungsi aktivasi yang linier, hasilnya tidak akan berbeda dengan hasil pada jaringan *single layer* (Setiawan, 2003). Fungsi aktivasi nonlinier yaitu sigmoid biner. Fungsi aktivasi sigmoid biner berbentuk kurva S yang digunakan dalam jaringan metode pelatihan *Backpropagation*.

2.5 Feed Forward Neural Networks

Feed Forward Neural Networks (FFNN) adalah bentuk arsitektur NN yang sedikitnya memiliki satu *hidden layer*. Model ini dapat digunakan untuk menangani kasus nonlinier karena dapat membentuk daerah keputusan yang lebih kompleks. Secara umum, model ini bekerja menerima suatu vektor dari *input-input* X dan kemudian menghitung suatu respon atau *output* Y dengan memproses (*propagating*) X melalui elemen-elemen proses yang saling terkait. FFNN memiliki 3 layer, yaitu *input*, *hidden* dan *output*.

Model FFNN adalah salah satu bentuk model NN yang dapat dipandang sebagai suatu kelompok model yang sangat fleksibel yang dapat digunakan untuk berbagai aplikasi (Suhartono, 2007). Estimasi parameter pada penelitian ini menerapkan algoritma *backpropagation* pada suatu optimisasi nonlinier *Least Squares*. Arsitektur algoritma *backpropagation* disajikan pada Gambar 2.2.



Gambar 2.2 Arsitektur Algoritma *Backpropagation*

Model FFNN dari Gambar 2.2 adalah sebagai berikut (Fithriasari, Iriawan, Ulama, dan Sutikno, 2013).

$$\bar{y}_{(t)} = f^0 \left[b^0 + \sum_{j=1}^q [w_j^0 f_j^h (b_j^h + \sum_{i=1}^p v_{ji}^h x_{i(k)})] \right] \quad (2.6)$$

dimana $\bar{y}_{(t)}$ adalah variabel prediksi (output variabel), v_{ji}^h adalah matrik dari input ke *hidden layer*, b_j^h adalah bias di *hidden layer*, w_j^0 adalah bobot dari *hidden layer* ke *output layer*, b^0 adalah bias dari *output layer*, f_j^h adalah fungsi aktivasi di *hidden layer*, f^0 adalah fungsi aktivasi di *output layer*.

2.6 Algoritma Backpropagation

Metode *backpropagation* adalah salah satu metode pelatihan pada jaringan saraf tiruan. Ciri metode ini yaitu meminimalkan *error* pada *output* yang dihasilkan oleh jaringan. Metode ini biasanya digunakan pada jaringan *multilayer*. Pelatihan dengan metode *backpropagation* terdiri dari tiga langkah, yaitu sebagai berikut (Setiawan, 2003).

1. Data dimasukkan ke *input* jaringan (*feed forward*)
2. Perhitungan dan *backpropagation* dari *error* yang bersangkutan
3. *Update* bobot dan bias

Langkah-langkah pelatihan *backpropagation* sebagai berikut.

1. Inisialisasi bobot dan bias
2. Ketika kondisi *stop* belum terpenuhi, maka dilakukan langkah sebagai berikut.

Tahap *Feed Forward*

- a. Setiap unit *input* menerima sinyal *input* x_i dan meneruskan ke unit *hidden layer*
- b. Setiap node *hidden layer* z_j menjumlahkan sinyal *input* yang terboboti, termasuk biasanya

$$z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (2.7)$$

dan menggunakan fungsi aktivasi yang telah ditentukan untuk menghitung sinyal *output* dari *hidden layer* unit yang bersangkutan

$$z_j = f(z_in_j) \quad (2.8)$$

lalu mengirim sinyal *output* tersebut ke seluruh unit pada unit *output*. Fungsi aktivasi yang digunakan pada penelitian ini adalah sigmoid biner, terdapat pada persamaan 2.3.

- c. Setiap unit *output* y_k pada lapisan menjumlahkan sinyal *input* yang terboboti, termasuk biasnya

$$y_in_k = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (2.9)$$

dan menggunakan fungsi aktivasi untuk menghitung sinyal *output* dari unit *output* yang bersangkutan

$$y_k = f(y_in_k) \quad (2.10)$$

lalu mengirim sinyal *output* ke seluruh unit pada unit *output*.

Tahap *Backpropagation*

- d. Setiap unit *output* y_k dengan target t dihitung informasi dari *output* target dengan rumus sebagai berikut.

$$\delta_k = (t_k - y_k) f'(y_in_k) \quad (2.11)$$

kemudian menghitung perubahan bobot *output* w_{jk} dan bobot bias *output* Δw_{0k} dengan *learning rate* α , dengan rumus berikut.

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (2.12)$$

$$\Delta w_{0k} = \alpha \delta_k$$

- e. Setiap unit *hidden layer* z_j menjumlahkan *input* delta (δ) yang terboboti

$$\delta_in_j = \sum_{k=1}^m \delta_k w_{jk} \quad (2.13)$$

kemudian hasilnya dikalikan dengan turunan dari fungsi aktivasi sigmoid biner untuk menghasilkan faktor koreksi *error* j sebagai berikut.

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad (2.14)$$

selanjutnya menghitung selisih perubahan bobot *hidden* v_{ij} dan bobot bias v_{0j} sebagai berikut.

$$\begin{aligned} \Delta v_{ij} &= \alpha \delta_j x_i \\ \Delta v_{0j} &= \alpha \delta_j \end{aligned} \quad (2.15)$$

Tahap *update* bobot dan bias

f. Setiap unit *output* y_k mengupdate bias dan bobotnya

$$\begin{aligned} w_{jk}(\text{baru}) &= w_{jk}(\text{lama}) + \Delta w_{jk} \\ v_{ij}(\text{baru}) &= v_{ij}(\text{lama}) + \Delta v_{ij} \end{aligned} \quad (2.16)$$

g. Uji saat kondisi *stop*

h. Untuk menentukan kondisi *stop* dapat dilakukan dengan dua cara yaitu dengan membatasi jumlah *epoch* atau nilai *Mean Square Error* (MSE) $< \varepsilon$ (dimana ε adalah sesuatu nilai yang sangat kecil dan ditetapkan yaitu 10^{-5}).

i. Setelah kondisi *stop* terpenuhi maka selanjutnya adalah membentuk model FFNN.

2.7 Pemilihan Model Terbaik

Dalam penelitian ini, terdapat banyak model yang digunakan untuk meramal data pada periode tertentu. Oleh karena itu, dibutuhkan kriteria untuk menentukan model yang terbaik dan akurat. Untuk menentukan model terbaik dapat menggunakan kriteria pemilihan model yang berdasarkan residual dan kesalahan peramalan (Wei, 2006). Adapun kriteria pemilihan model yang berdasarkan residual adalah:

1. *Mean Square Error* (MSE)

Suatu teknik yang menghasilkan kesalahan moderat mungkin lebih baik untuk salah satu yang memiliki kesalahan kecil tapi kadang-kadang menghasilkan sesuatu yang sangat besar. Rumus MSE didefinisikan sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2.17)$$

Ada kalanya rumus MSE sangat berguna untuk menghitung kesalahan-kesalahan peramalan dalam bentuk persentase daripada jumlah.

2. *Akaike's Information Criterion (AIC)*

Diasumsikan bahwa model deret waktu mempunyai M parameter. Nilai AIC didefinisikan sebagai berikut.

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M \quad (2.18)$$

dengan:

n : banyaknya residual

M : jumlah parameter di dalam model

$\hat{\sigma}_a^2$: varians dari residual yang diestimasi dengan *Maximum Likelihood Estimation (MLE)*

(Halaman ini sengaja dikosongkan)

BAB III

METODOLOGI PENELITIAN

Pada bagian ini akan dijelaskan mengenai metode dan tahapan-tahapan dalam melakukan analisis untuk menyelesaikan permasalahan dalam penelitian ini meliputi sumber data, variabel penelitian, dan langkah penelitian. Metode yang digunakan adalah *Feed Forward Neural Networks* (FFNN).

3.1 Sumber Data

Sumber data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) Provinsi Sumatera Barat. Data yang digunakan mengenai pendapatan asli daerah, pengeluaran daerah, PDRB, jumlah penduduk, jumlah perusahaan, jumlah hotel, dan jumlah pelanggan listrik pada tahun 2012-2015. Dengan unit penelitian yaitu tiap kabupaten/kota di Provinsi Sumatera Barat yang terdiri atas 12 kabupaten dan 7 kota.

3.2 Variabel Penelitian

Variabel respon yang digunakan adalah Pendapatan Asli Daerah, sedangkan variabel prediktornya adalah pengeluaran pemerintah, PDRB, jumlah penduduk, jumlah perusahaan, jumlah hotel, dan jumlah pelanggan listrik. Selengkapnya dapat dilihat pada Tabel 3.1.

Tabel 3.1 Variabel Respon dan Prediktor dalam Penelitian

Variabel	Keterangan	Skala Data
Y	Pendapatan Asli Daerah	Rasio
X_1	Pengeluaran Pemerintah	Rasio
X_2	PDRB	Rasio
X_3	Jumlah Penduduk	Rasio
X_4	Jumlah Perusahaan	Rasio
X_5	Jumlah Hotel	Rasio
X_6	Jumlah Pelanggan Listrik	Rasio

3.3 Struktur Data

Berikut struktur data pada penelitian ini, dapat dilihat pada Tabel 3.2.

Tabel 3.2 Struktur Data

Tahun	Kabupaten/Kota	Y	X_1	X_2	X_3	X_4	X_5	X_6
2012	1	Y ₁	X _{1,1}	X _{1,2}	X _{1,3}	X _{1,4}	X _{1,5}	X _{1,6}
	2	Y ₂	X _{2,1}	X _{2,2}	X _{2,3}	X _{2,4}	X _{2,5}	X _{2,6}
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	19	Y ₁₉	X _{19,1}	X _{19,2}	X _{19,3}	X _{19,4}	X _{19,5}	X _{19,6}
2013	20	Y ₂₀	X _{20,1}	X _{20,2}	X _{20,3}	X _{20,4}	X _{20,5}	X _{20,6}
	21	Y ₂₁	X _{21,1}	X _{21,2}	X _{21,3}	X _{21,4}	X _{21,5}	X _{21,6}
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	38	Y ₃₈	X _{38,1}	X _{38,2}	X _{38,3}	X _{38,4}	X _{38,5}	X _{38,6}
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015	77	Y ₇₇	X _{77,1}	X _{77,2}	X _{77,3}	X _{77,4}	X _{77,5}	X _{77,6}
	78	Y ₇₈	X _{78,1}	X _{78,2}	X _{78,3}	X _{78,4}	X _{78,5}	X _{78,6}
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	95	Y ₉₅	X _{95,1}	X _{95,2}	X _{95,3}	X _{95,4}	X _{95,5}	X _{95,6}

3.4 Langkah Analisis

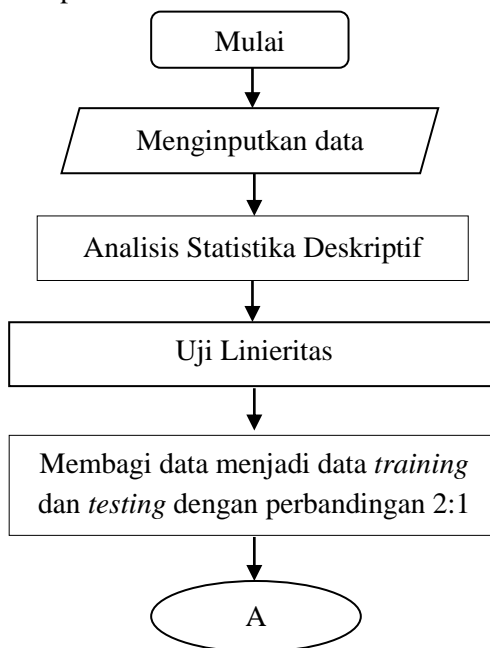
Langkah analisis yang digunakan dalam memodelkan jumlah PAD di Provinsi Sumatera Barat menggunakan *Feed Forward Neural Network* (FFNN) adalah sebagai berikut.

- Menginputkan data penelitian
- Menganalisis karakteristik PAD di Provinsi Sumatera Barat
- Melakukan Uji *Linearitas*
- Membagi data menjadi *training* dan *testing*, dengan perbandingan 2:1
- Menginputkan data variabel bebas di *input layer*

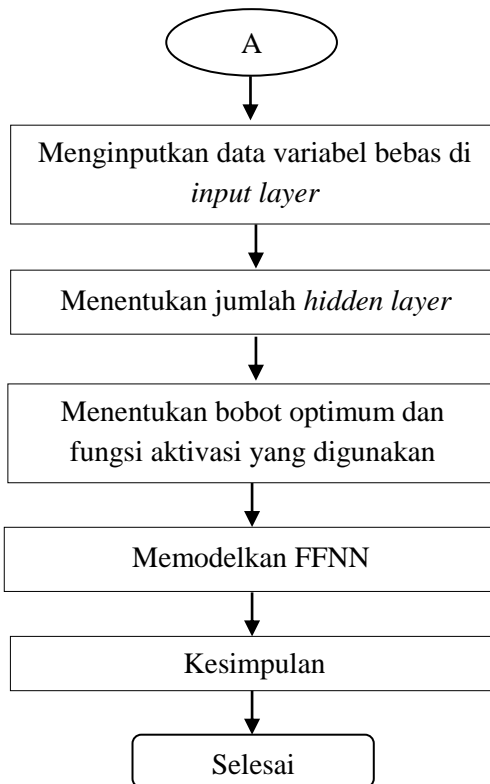
- f. Menentukan jumlah *hidden layer* yang paling sesuai berdasarkan nilai MSE dan AIC yang dihasilkan. Dengan menggunakan sepuluh neuron di *hidden layer*, jumlah *hidden layer* yang paling sesuai adalah yang memiliki nilai MSE dan AIC terkecil.
- g. Melakukan perhitungan untuk mencari nilai bobot yang optimum dengan jumlah unit neuron pada *hidden layer* yang berbeda-beda menggunakan algoritma *Backpropagation*.
- h. Menetapkan model FFNN berdasarkan arsitektur yang terbaik.
- i. Menarik kesimpulan dari hasil analisis yang diperoleh.

3.5 Diagram Alir

Berdasarkan langkah-langkah analisis dengan menggunakan metode *Neural Networks*, maka diagram alir dalam penelitian ini dapat dilihat pada Gambar 3.1.



Gambar 3.1 Diagram Alir



Gambar 3.1 Diagram Alir (Lanjutan)

BAB IV ANALISIS DAN PEMBAHASAN

Pada bab ini akan menjelaskan beberapa hal yang dilakukan untuk mencapai tujuan menjawab permasalahan dalam penelitian ini. Hal-hal yang akan dibahas diantaranya meliputi deskripsi pendapatan asli daerah di Provinsi Sumatera Barat tahun 2015 berdasarkan kabupaten/kota beserta variabel prediktor yang diduga berpengaruh, dan melakukan pemodelan pendapatan asli daerah di Provinsi Sumatera Barat menggunakan *Feed Forward Neural Networks* (FFNN) mulai dari penentuan bobot *neural networks*, *preprocessing*, penentuan jumlah neuron di *hidden layer*, penentuan fungsi aktivasi di *hidden layer* dan *output layer* hingga menginterpretasikan hasil model FFNN.

4.1 Karakteristik Pendapatan Asli Daerah (PAD) di Provinsi Sumatera Barat Tahun 2015

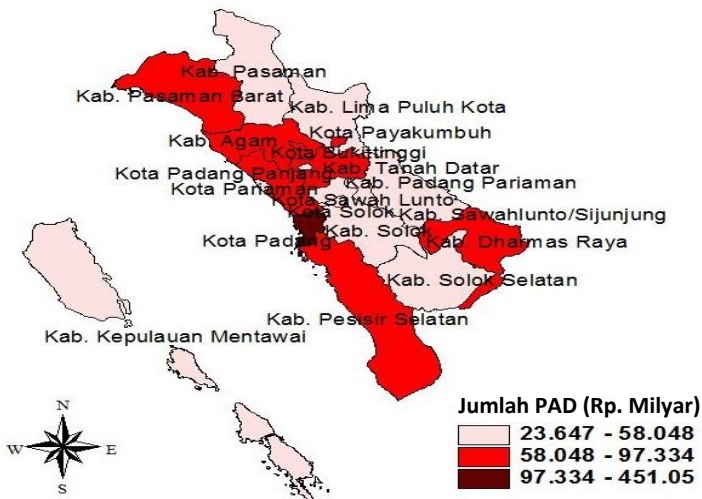
Sebagaimana yang dijelaskan pada subbab 3.2 bahwa penelitian ini menggunakan data pendapatan asli daerah di 19 kabupaten/kota di Provinsi Sumatera Barat tahun 2015 dengan variabel prediktor yang diduga berpengaruh. Data variabel yang digunakan tersebut dideskripsikan menurut statistika deskriptif yaitu berdasarkan nilai rata-rata (*mean*), nilai *devian* atau keragaman data, serta nilai minimum dan maksimum dari data-data yang tersedia. Semuanya terangkum dalam Tabel 4.1 sebagai berikut.

Tabel 4.1 Statistika Deskriptif Variabel Penelitian

Variabel	Rata-rata	Varians	Minimum	Maksimum
Y	78,7	8484,9	23,6	451,1
X ₁	904,0	132938,9	483,6	1948,4
X ₂	7421,0	54908195,0	2066,0	35198,0
X ₃	273,5	44330,4	50,9	902,4
X ₄	318,6	48914,8	95,0	1029,0
X ₅	19,5	496,3	2,0	93,0
X ₆	60,2	2259,5	6,3	230,9

Berdasarkan Tabel 4.1 diperoleh informasi bahwa diantara 19 kabupaten/kota di Provinsi Sumatera Barat, daerah dengan pendapatan asli daerah yang kecil terdapat di Kota Pariaman sebesar Rp. 23,6 milyar, sedangkan jumlah pendapatan asli daerah terbanyak terdapat di Kota Padang sebanyak Rp. 451,1 milyar. Selain itu, diketahui bahwa rata-rata jumlah pendapatan asli daerah tahun 2015 sebesar Rp. 78,7 milyar dengan nilai varians sebesar Rp. 8484,9 milyar.

Berdasarkan data yang ada diketahui bahwa hanya ada 3 kabupaten/kota yang memiliki pendapatan asli daerah melebihi rata-rata provinsi. Nilai varians menunjukkan bahwa jumlah pendapatan asli daerah antara kabupaten/kota di Provinsi Sumatera Barat sangat bervariasi, ada yang jumlahnya hanya puluhan milyar tetapi ada juga yang ratusan milyar. Secara rinci penyebaran pendapatan asli daerah disajikan pada Gambar 4.1.



Gambar 4.1 Penyebaran Jumlah Pendapatan Asli Daerah di Provinsi Sumatera Barat (Y)

Gambar 4.1 menunjukkan kabupaten/kota di Provinsi Sumatera Barat berdasarkan data jumlah pendapatan asli daerah

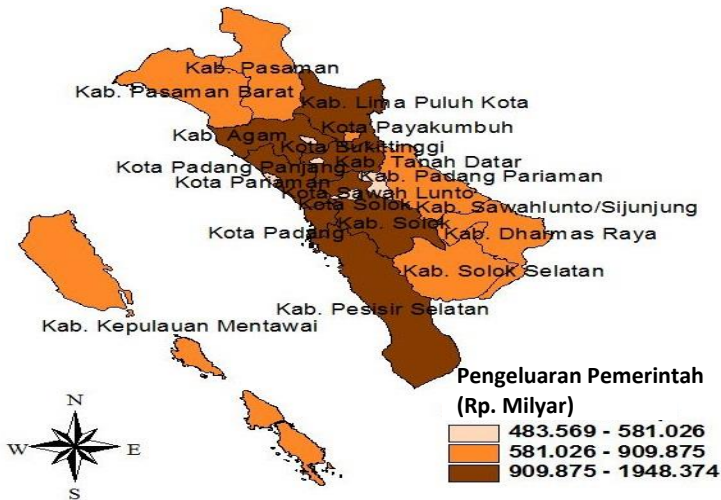
pada Lampiran 1, dengan kategori rendah, sedang dan tinggi. Sebagian besar kabupaten/kota di Provinsi Sumatera Barat dengan jumlah pendapatan asli daerah masih berada pada kategori rendah, wilayah dengan jumlah pendapatan asli daerah pada kategori rendah ditandai dengan warna merah muda yang berkisar 23,647-58,048 milyar rupiah terdapat di 11 kabupaten/kota. Jumlah pendapatan asli daerah pada kategori sedang ditandai dengan warna merah yang berkisar antara 58,048 – 97,334 milyar rupiah terdapat di 7 kabupaten/kota dan pada kategori tertinggi ditandai dengan warna merah tua yang berkisar 97,334 – 451,05 milyar rupiah terdapat di Kota Padang. Dimana 16 kabupaten/kota diantaranya berada dibawah rata-rata provinsi.

Deskripsi dari keenam variabel prediktor antara lain adalah jumlah pengeluaran pemerintah, PDRB, jumlah penduduk, jumlah perusahaan, jumlah hotel dan jumlah pelanggan listrik di tiap kabupaten/kota di Provinsi Sumatera Barat. Daerah dengan pengeluaran pemerintah yang kecil terdapat di Kota Solok sebesar Rp. 483,6 milyar, sedangkan pengeluaran pemerintah terbanyak terdapat di Kota Padang sebesar Rp. 1948,4 milyar. Selain itu, diketahui bahwa rata-rata jumlah pengeluaran pemerintah di tiap kabupaten/kota di Provinsi Sumatera Barat sebesar Rp. 904 milyar dengan nilai varians sebesar Rp. 132938,9 milyar.

Berdasarkan data yang ada diketahui bahwa hanya ada 8 kabupaten/kota yang memiliki jumlah pengeluaran pemerintah melebihi rata-rata provinsi. Nilai varians menunjukkan bahwa pengeluaran pemerintah antara kabupaten/kota di Provinsi Sumatera Barat sangat bervariasi, ada yang jumlahnya hanya ratusan milyar tetapi ada juga yang ribuan milyar. Secara rinci penyebaran pengeluaran pemerintah disajikan pada Gambar 4.2.

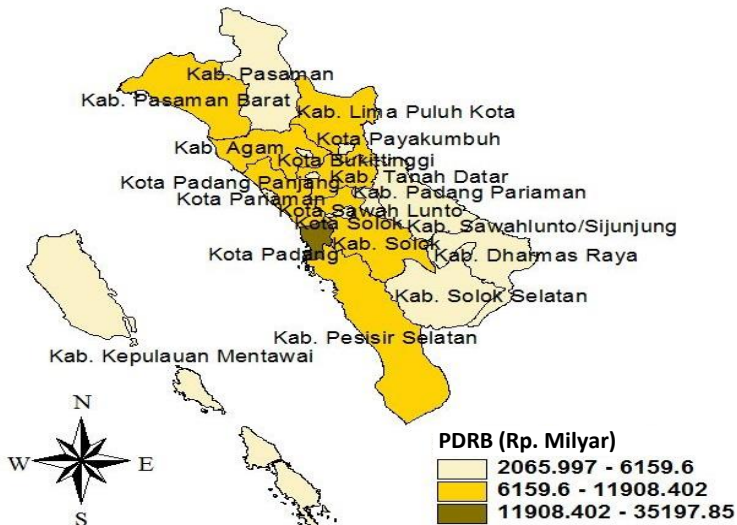
Gambar 4.2 menunjukkan kabupaten/kota di Provinsi Sumatera Barat berdasarkan data pengeluaran pemerintah pada kategori rendah, sedang dan tinggi. Pengeluaran pemerintah menunjukkan persebaran yang hampir merata yakni untuk kategori tinggi ditandai dengan warna coklat tua yang berkisar antara 909,875 – 1948,374 milyar rupiah terdapat pada 8 kabupaten/kota,

pada kategori sedang ditandai dengan warna coklat yang berkisar antara 581,026 - 909,875 milyar rupiah terdapat di 6 kabupaten/kota, dan pada kategori rendah ditandai warna coklat muda yang berkisar 483,569-581,026 milyar rupiah terdapat pada 5 kabupaten/kota. Dimana 11 kabupaten/kota pada kategori rendah dan sedang berada dibawah rata-rata provinsi.



Gambar 4.2 Persebaran Pengeluaran Pemerintah (X_1)

Daerah dengan PDRB yang kecil terdapat di Kota Padang Panjang sebesar Rp. 2066 milyar, sedangkan jumlah PDRB terbanyak terdapat di Kota Padang sebesar Rp. 35198 milyar. Selain itu, diketahui bahwa rata-rata PDRB di tiap kabupaten/kota Provinsi Sumatera Barat sebesar Rp. 7421 milyar dengan nilai varians Rp. 54908195 milyar. Berdasarkan data yang ada diketahui bahwa hanya ada 8 kabupaten/kota yang memiliki PDRB melebihi rata-rata provinsi. Nilai varians menunjukkan bahwa terdapat perbedaan yang sangat signifikan PDRB antar kabupaten/kota di Provinsi Sumatera Barat. Secara rinci penyebaran PDRB disajikan pada Gambar 4.3.



Gambar 4.3 Persebaran PDRB (X_2)

Gambar 4.3 menunjukkan kabupaten/kota di Provinsi Sumatera Barat berdasarkan data PDRB yang menunjukkan persebaran yang hampir merata yakni untuk kategori rendah ditandai dengan warna kuning muda yang berkisar antara 2065,997 – 6169,6 milyar rupiah terdapat 11 kabupaten/kota, pada kategori sedang ditandai dengan warna kuning yang berkisar antara 6159,6 – 11908,402 milyar rupiah terdapat di 7 kabupaten/kota, dan pada kategori tinggi ditandai dengan hijau yang berkisar antara 11908,402 – 35197,85 milyar rupiah terdapat di Kota Padang. Dimana 11 kabupaten/kota diantara kategori rendah dan sedang berada dibawah rata-rata provinsi.

Daerah dengan jumlah penduduk yang kecil terdapat di Kota Padang Panjang sebesar 50,9 ribu, sedangkan jumlah penduduk terbanyak terdapat di Kota Padang sebesar 902,4 ribu orang. Selain itu, diketahui bahwa rata-rata jumlah penduduk di tiap kabupaten/kota Provinsi Sumatera Barat sebesar 273,5 ribu orang dengan nilai varians 44330,4 ribu. Berdasarkan data yang ada diketahui bahwa hanya ada 8 kabupaten/kota yang memiliki

jumlah penduduk melebihi rata-rata provinsi. Nilai varians menunjukkan bahwa terdapat perbedaan yang sangat signifikan jumlah penduduk antar kabupaten/kota di Provinsi Sumatera Barat. Secara rinci penyebaran jumlah penduduk disajikan pada Gambar 4.4.



Gambar 4.4 Persebaran Jumlah penduduk (X_3)

Gambar 4.4 menunjukkan kabupaten/kota di Provinsi Sumatera Barat berdasarkan data jumlah penduduk yang menunjukkan persebaran yang hampir merata yakni untuk kategori rendah ditandai dengan warna hijau muda yang berkisar antara 50,883 – 223,112 ribu terdapat 10 kabupaten/kota, pada kategori sedang ditandai dengan warna hijau yang berkisar antara 223,12 – 476,881 ribu terdapat di 8 kabupaten/kota, dan pada kategori tinggi ditandai dengan warna hijau tua yang berkisar 476,881 – 902,413 ribu terdapat di Kota Padang. Dimana 11 kabupaten/kota diantara kategori rendah dan sedang berada dibawah rata-rata provinsi.

Daerah dengan jumlah perusahaan yang sedikit terdapat di Kabupaten Kepulauan Mentawai sebesar 95 perusahaan, sedangkan jumlah perusahaan terbanyak terdapat di Kota Padang

sebesar 1029 perusahaan. Selain itu, diketahui bahwa rata-rata jumlah perusahaan di tiap kabupaten/kota Provinsi Sumatera Barat adalah 318,6 perusahaan dengan nilai varians 48914,8. Berdasarkan data yang ada diketahui bahwa hanya ada 7 kabupaten/kota yang memiliki jumlah perusahaan melebihi rata-rata provinsi. Nilai varians menunjukkan bahwa terdapat perbedaan yang sangat signifikan antar kabupaten/kota di Provinsi Sumatera Barat. Secara rinci penyebaran jumlah perusahaan disajikan pada Gambar 4.5.



Gambar 4.5 Persebaran Jumlah Perusahaan (X_4)

Gambar 4.5 menunjukkan kabupaten/kota di Provinsi Sumatera Barat berdasarkan data jumlah perusahaan, jumlah perusahaan menunjukkan persebaran yang tidak merata yakni untuk kategori tinggi ditandai dengan warna hijau tua yang berkisar antara 617–1029 perusahaan terdapat di Kota Padang, pada kategori sedang ditandai dengan warna hijau yang berkisar antara 306–617 perusahaan terdapat di 6 kabupaten/kota, dan pada kategori rendah ditandai dengan warna hijau muda yang berkisar antara 95-306 perusahaan terdapat 12 kabupaten/kota. Dimana 12

kabupaten/kota diantara kategori rendah dan sedang berada dibawah rata-rata provinsi.

Daerah dengan jumlah hotel yang sedikit terdapat di Kota Sawahlunto sebanyak 2 hotel, sedangkan jumlah hotel terbanyak terdapat di Kota Padang sebesar 93 hotel. Selain itu, diketahui bahwa rata-rata jumlah hotel di tiap kabupaten/kota Provinsi Sumatera Barat sebesar 19,5 hotel dengan nilai varians 496,3. Berdasarkan data yang ada diketahui bahwa hanya ada 4 kabupaten/kota yang memiliki jumlah hotel melebihi rata-rata provinsi. Nilai varians menunjukkan terdapat perbedaan yang sangat signifikan jumlah hotel antar kabupaten/kota di Provinsi Sumatera Barat. Secara rinci penyebaran jumlah hotel disajikan pada Gambar 4.6.

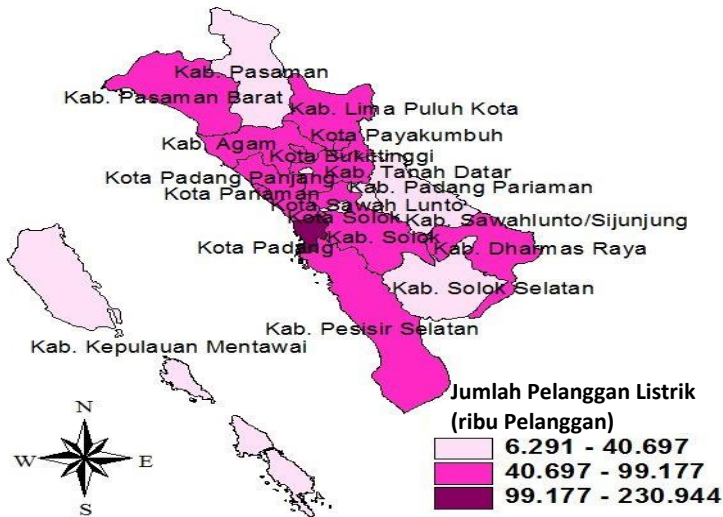


Gambar 4.6 Persebaran Jumlah Hotel (X_5)

Gambar 4.6 menunjukkan kabupaten/kota di Provinsi Sumatera Barat berdasarkan data jumlah hotel, jumlah hotel menunjukkan persebaran yang tidak merata yakni untuk kategori tinggi ditandai dengan warna biru tua yang berkisar 26-93 hotel terdapat di Kota Padang dan Kota Bukittinggi, pada kategori sedang ditandai dengan warna biru yang berkisar antara 14-26

hotel terdapat di 6 kabupaten/kota, dan pada kategori rendah ditandai dengan warna biru muda yang berkisar antara 2-14 hotel terdapat 11 kabupaten/kota. Dimana 15 kabupaten/kota diantaranya berada dibawah rata-rata provinsi.

Daerah dengan jumlah pelanggan listrik yang sedikit terdapat di Kabupaten Kepulauan Mentawai sebesar 6,3 ribu pelanggan, sedangkan jumlah pelanggan listrik terbanyak terdapat di Kota Padang sebesar 230,9 ribu pelanggan. Selain itu, diketahui bahwa rata-rata jumlah pelanggan listrik di tiap kabupaten/kota Provinsi Sumatera Barat sebesar 60,2 ribu pelanggan dengan nilai varians 2259,5 ribu. Berdasarkan data yang ada diketahui bahwa hanya ada 8 kabupaten/kota yang memiliki jumlah pelanggan listrik melebihi rata-rata provinsi. Nilai varians menunjukkan yang menunjukkan terdapat perbedaan yang sangat signifikan jumlah pelanggan listrik antar kabupaten/kota di Provinsi Sumatera Barat. Secara rinci penyebaran jumlah pelanggan listrik disajikan pada Gambar 4.7.




Gambar 4.7 Persebaran Jumlah Pelanggan Listrik (X_6)

Gambar 4.7 menunjukkan Kabupaten/Kota di Provinsi Sumatera Barat berdasarkan data jumlah pelanggan listrik, jumlah pelanggan listrik menunjukkan persebaran yang tidak merata yakni untuk kategori tinggi ditandai dengan warna merah tua yang berkisar antara 99,177-230,944 ribu pelanggan terdapat di Kota Padang, pada kategori sedang ditandai dengan warna merah berkisar antara 40,697-99,177 ribu pelanggan terdapat di 11 kabupaten/kota, dan pada kategori rendah ditandai dengan warna merah muda yang berkisar antara 6,291-40,697 ribu pelanggan terdapat 7 kabupaten/kota. Dimana 11 kabupaten/kota diantaranya berada dibawah rata-rata provinsi.

4.2 Uji Linieritas Data

Uji linieritas data dilakukan untuk mengetahui apakah terdapat pola linier pada data. Pada penelitian ini uji linieritas bertujuan untuk memilih fungsi aktivasi. Sebagai gambaran hubungan data pendapatan asli daerah di Provinsi Sumatera Barat dengan faktor yang diduga berpengaruh, disajikan *scatter plot* pada Gambar 4.8



Gambar 4.8 Scatter Plot Data Pendapatan Asli Daerah terhadap faktor yang diduga berpengaruh

Uji linieritas data pendapatan asli daerah di Provinsi Sumatera Barat dalam penelitian ini menggunakan Uji Terasvirta.

$H_0 : f(x)$ adalah fungsi linier dalam x atau model linier

$H_1 : g(x)$ adalah fungsi nonlinier dalam x atau model nonlinier

Statistik Uji:

$$F_{hitung} = \frac{(SSR_0 - SSR_1)/m}{SSR_1/(n - 1 - p - m)}$$

Keputusan : Tolak H_0 , jika $F_{hitung} > F_{tabel}$ dengan derajat bebas m dan $(n - 1 - p - m)$

Berdasarkan uji terasvirta yang telah dilakukan, diperoleh nilai F_{hitung} sebesar 62.3834. Nilai F_{tabel} dengan nilai signifikansi α (0.05) sebesar 3.9287. Nilai F_{hitung} lebih besar dari nilai F_{tabel} sehingga keputusan Tolak H_0 , hal ini berarti bahwa terdapat pola nonlinier pada data pendapatan asli daerah di Provinsi Sumatera Barat. Dengan demikian, fungsi aktivasi yang digunakan pada penelitian ini menggunakan fungsi aktivasi nonlinier. Fungsi aktivasi nonlinier salah satunya adalah fungsi aktivasi sigmoid biner, seperti yang dijelaskan pada subbab 2.4.

4.3 Pemodelan dan Peramalan Pendapatan Asli Daerah dengan FFNN

Data yang digunakan pada analisis ini adalah data pendapatan asli daerah dari tahun 2012 sampai tahun 2015. Data yang digunakan adalah data *time series*, maka ditambahkan variabel baru berupa lag 1 untuk setiap variabel bebas yang dinotasikan $X_{i(t-1)}$ dengan $i = 1, 2, 3, 4, 5$ dan 6, serta $t = 2, 3$, dan 4. Secara rinci disajikan struktur data dengan penambahan lag 1 masing-masing variabel bebas pada Tabel 4.2.

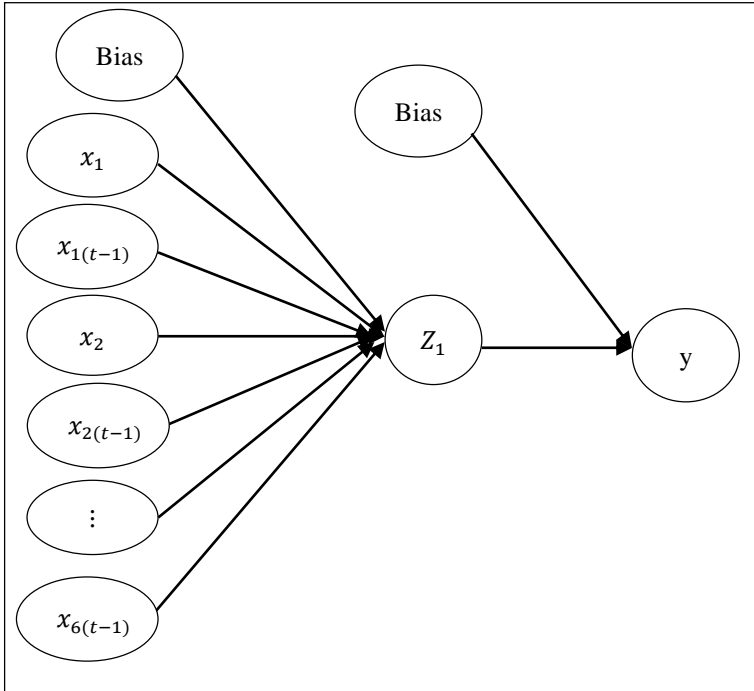
Sebelum pembentukan model pendapatan asli daerah dengan metode FFNN, terlebih dahulu dilakukan pembagian data menjadi data *training* dan *testing*. Pembagian data *training* dan *testing* dengan perbandingan 2:1. Data *training* digunakan untuk membentuk model dan data *testing* digunakan untuk menguji kebaikan model. Data *training* yang digunakan pada penelitian ini adalah data tahun 2013 dan 2014 dengan jumlah data sebanyak 38

pengamatan. Data *testing* yang digunakan adalah data tahun 2015 dengan jumlah data sebanyak 19 pengamatan.

Tabel 4.2 Struktur Data dengan Penambahan Lag 1

Tahun	Kabupaten/Kota	Y	X_1	$X_{1,(t-1)}$...	X_6	$X_{6,(t-1)}$
2012	1	Y_1	$X_{1,1}$	*	...	$X_{1,6}$	*
	2	Y_2	$X_{2,1}$	*	...	$X_{2,6}$	*
	\vdots	\vdots	\vdots	\vdots	...	\vdots	\vdots
	19	Y_{19}	$X_{19,1}$	*	...	$X_{19,6}$	*
2013	20	Y_{20}	$X_{20,1}$	$X_{1,1}$...	$X_{20,6}$	$X_{1,6}$
	21	Y_{21}	$X_{21,1}$	$X_{2,1}$...	$X_{21,6}$	$X_{2,6}$
	\vdots	\vdots	\vdots	\vdots	...	\vdots	\vdots
	38	Y_{38}	$X_{38,1}$	$X_{19,1}$...	$X_{38,6}$	$X_{19,6}$
\vdots	\vdots	\vdots	\vdots	\vdots	...	\vdots	\vdots
2015	77	Y_{77}	$X_{77,1}$	$X_{39,1}$...	$X_{77,6}$	$X_{39,6}$
	78	Y_{78}	$X_{78,1}$	$X_{40,1}$...	$X_{78,6}$	$X_{40,6}$
	\vdots	\vdots	\vdots	\vdots	...	\vdots	\vdots
	95	Y_{95}	$X_{95,1}$	$X_{76,1}$...	$X_{95,6}$	$X_{76,6}$

Jaringan FFNN yang digunakan dalam penelitian ini adalah *multilayer perceptron* dengan metode pelatihan *backpropagation* dengan satu *hidden layer* (lapisan tersembunyi). Jumlah neuron pada *hidden layer* telah ditentukan, yaitu neuron 1, 2, 3, 4, 5, 6, 7, 8, 9, dan 10, serta replikasi yang digunakan sebanyak 10 replikasi. Arsitektur jaringan FFNN disajikan pada Gambar 4.9. Fungsi aktivasi yang digunakan pada *hidden layer* dan *output layer* adalah fungsi sigmoid biner. *Preprocessing* yang digunakan adalah *normalized*, karena mengikuti fungsi aktivasi yang memiliki range antara 0 sampai 1.



Gambar 4.9 Arsitektur Jaringan FFNN dengan 1 Neuron *Hidden Layer*

4.3.1 Kriteria Kebaikan Model pada Data Pendapatan Asli Daerah

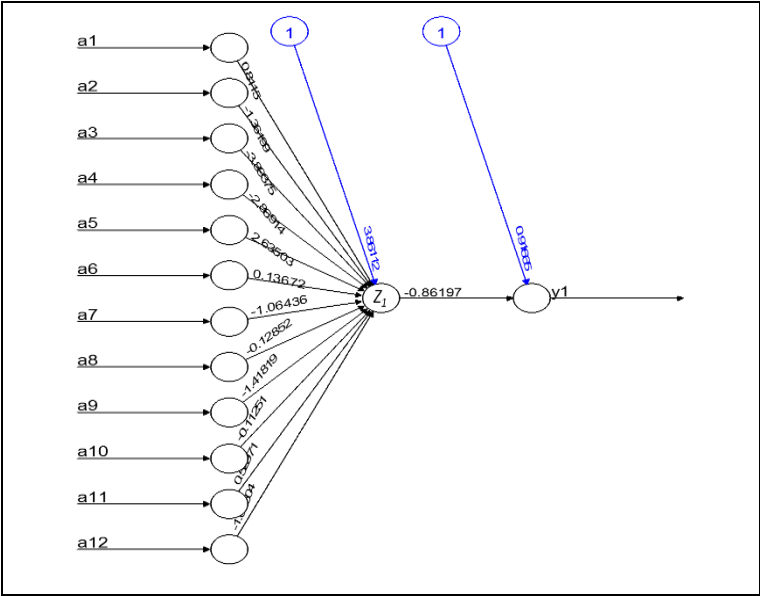
Uji kebaikan model pada data *training* dan *testing* dengan 10 replikasi masing-masing neuron *hidden layer* menggunakan nilai MSE dan AIC adalah sebagai berikut.

1. Neuron 1

Uji kebaikan model sebanyak 1 neuron *hidden layer* disajikan pada Tabel 4.3. Tabel 4.3 menunjukkan bahwa pada data *training* dan data *testing* diperoleh model FFNN optimum 1 neuron di *hidden layer* pada replikasi 5. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.10.

Tabel 4.3 Uji Kebaikan Model dengan 1 Neuron

Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
1	362,699	-20,446	2482,882	68,751
2	195,011	-44,026	1209,394	55,084
3	1382,081	30,389	4129,600	78,417
4	2847,673	57,860	8071,460	91,150
5	120,998	-62,163	513,771	38,818
6	234,428	-37,030	2056,437	65,170
7	140,630	-56,449	540,087	39,767
8	190,203	-44,974	946,332	50,424
9	257,429	-33,474	1480,497	58,927
10	318,420	-25,394	2013,166	64,766



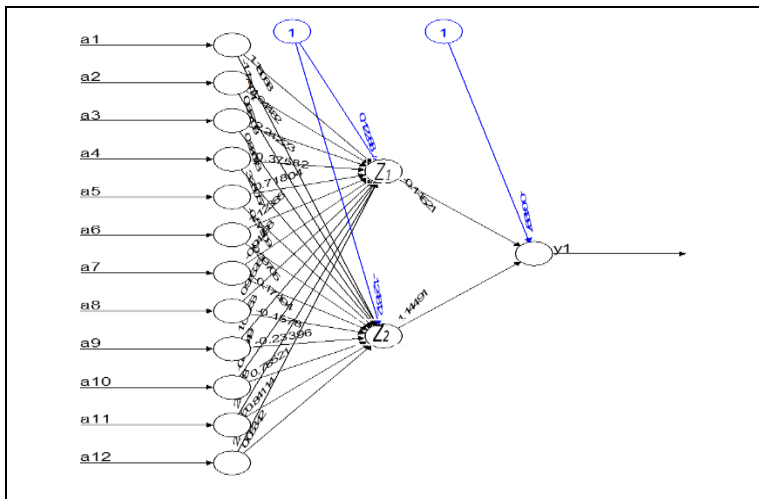
Gambar 4.10 Arsitektur Jaringan FFNN 1 Neuron

2. Neuron 2

Uji kebaikan model sebanyak 2 neuron *hidden layer* disajikan pada Tabel 4.4.

Tabel 4.4 Uji Kebaikan Model dengan 2 Neuron

Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
1	233,582	-9,168	1407,113	85,961
2	230,308	-9,704	1531,373	87,569
3	264,201	-4,487	1104,201	81,355
4	301,041	0,473	1548,726	87,783
5	262,759	-4,695	1572,881	88,077
6	303,371	0,766	2481,300	96,739
7	244,337	-7,457	478,203	65,455
8	198,646	-15,324	2117,561	93,727
9	310,060	1,595	1621,544	88,656
10	211,304	-12,977	1316,372	84,695




Gambar 4.11 Arsitektur Jaringan FFNN 2 Neuron

Tabel 4.4 menunjukkan bahwa pada data *training* dan data *testing* diperoleh model FFNN optimum 2 neuron di *hidden layer* pada replikasi 8. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.11.

3. Neuron 3
 Uji kebaikan model sebanyak 3 neuron *hidden layer* disajikan pada Tabel 4.5.

Tabel 4.5 Uji Kebaikan Model dengan Neuron 3				
Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
1	123,853	-5,276	684,135	82,154
2	263,859	23,464	2120,720	121,755
3	245,340	20,698	1416,661	114,090
4	251,317	21,613	1773,216	118,355
5	321,947	31,025	824,823	103,813
6	233,850	18,875	1370,356	113,458
7	400,015	39,275	6982,833	144,398
8	217,350	16,095	814,895	103,583
9	314,515	30,137	1439,760	114,397
10	272,412	24,676	1510,402	115,307

Tabel 4.5 menunjukkan bahwa pada data *training* dan data *testing* diperoleh model FFNN optimum 3 neuron di *hidden layer* pada replikasi 1. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.12.




Gambar 4.12 Arsitektur Jaringan FFNN 3 Neuron

4. Neuron 4
 Uji kebaikan model sebanyak 4 neuron *hidden layer* disajikan pada Tabel 4.6.

Tabel 4.6 Uji Kebaikan Model dengan Neuron 4

Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
1	325,407	59,431	3023,845	156,496
2	215,046	43,690	1606,629	144,480
3	198,094	40,570	1249,984	139,711
4	211,846	43,121	1259,024	139,848
5	335,790	60,624	1561,388	143,938
6	236,444	47,295	1023,339	135,910
7	382,002	65,524	9118,052	177,467
8	139,641	27,283	425,178	119,222
9	192,043	39,391	1650,264	144,990
10	209,357	42,671	1444,861	142,464

Tabel 4.6 menunjukkan bahwa pada data *training* dan data *testing* diperoleh model FFNN optimum 4 neuron di *hidden layer* pada replikasi 8. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.13.



Gambar 4.13 Arsitektur Jaringan FFNN 4 Neuron

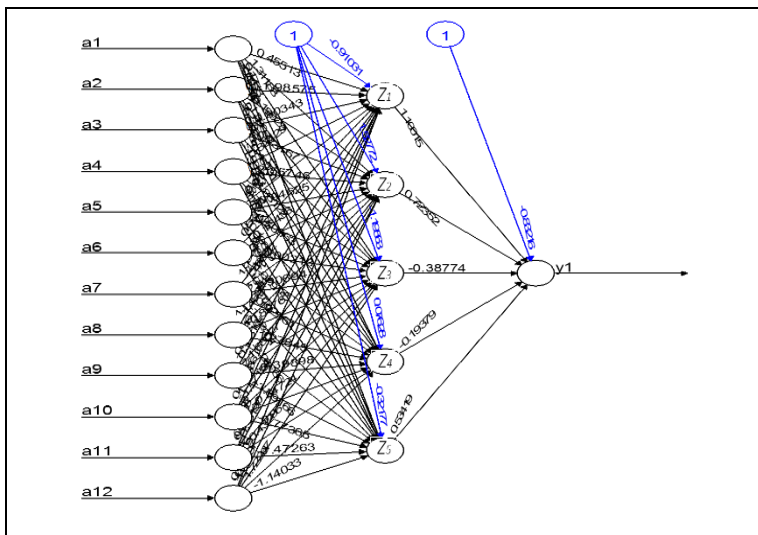
5. Neuron 5
Uji kebaikan model sebanyak 5 neuron *hidden layer* disajikan pada Tabel 4.7.

Tabel 4.7 Uji Kebaikan Model dengan Neuron 5

Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
1	317,016	86,438	1872,848	175,394
2	261,243	79,085	434,605	147,639
3	219,277	72,431	1456,845	170,621
4	449,139	99,677	1363,326	169,361
5	187,830	66,548	1200,676	166,947

Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
6	346,918	89,863	930,679	162,107
7	177,845	64,473	1381,478	169,612
8	336,679	88,725	3908,781	189,373
9	195,583	68,085	759,286	158,240
10	657,798	114,176	1586,310	172,239

Tabel 4.7 menunjukkan bahwa pada data *training* dan data *testing* diperoleh model FFNN optimum 5 neuron di *hidden layer* pada replikasi 7. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.14.



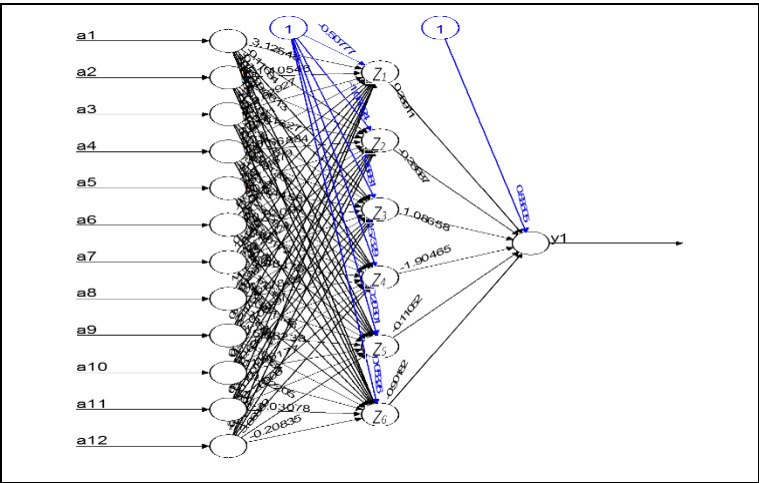
Gambar 4.14 Arsitektur Jaringan FFNN 5 Neuron

6. Neuron 6
Uji kebaikan model sebanyak 6 neuron *hidden layer* disajikan pada Tabel 4.8.

Tabel 4.8 Uji Kebaikan Model dengan Neuron 6

Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
1	356,542	118,903	1506,266	199,255
2	356,446	118,893	1012,311	191,704
3	321,078	114,922	1487,324	199,015
4	256,280	106,356	2452,249	208,515
5	180,569	93,050	1637,430	200,841
6	213,964	99,499	1938,476	204,048
7	345,939	117,756	7925,242	230,803
8	150,605	86,155	3089,860	212,906
9	168,857	90,502	794,994	187,113
10	251,992	105,715	530,887	179,441

Tabel 4.8 menunjukkan bahwa pada data *training* dan data *testing* diperoleh model FFNN optimum 6 neuron di *hidden layer* pada replikasi 8. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.15.




Gambar 4.15 Arsitektur Jaringan FFNN 6 Neuron

7. Neuron 7

Uji kebaikan model sebanyak 7 neuron *hidden layer* disajikan pada Tabel 4.9.

Tabel 4.9 Uji Kebaikan Model dengan Neuron 7

Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
1	280,585	137,799	1071,377	220,782
2	309,674	141,548	2761,333	238,770
3	188,783	122,741	1190,315	222,782
4	242,377	132,237	497,056	206,190
5	313,702	142,039	1847,870	231,139
6	213,946	127,495	2381,937	235,962
7	175,260	119,916	1950,468	232,165
8	308,493	141,403	994,609	219,369
9	208,644	126,542	2176,429	234,248
10	275,221	137,066	1024,635	219,934



Gambar 4.16 Arsitektur Jaringan FFNN 7 Neuron

Tabel 4.9 menunjukkan bahwa pada data *training* dan data *testing* diperoleh model FFNN optimum 7 neuron di *hidden layer* pada replikasi 7. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.16.


8. Neuron 8

Uji kebaikan model sebanyak 8 neuron *hidden layer* disajikan pada Tabel 4.10.

Tabel 4.10 Uji Kebaikan Model dengan Neuron 8

Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
1	261,892	163,179	1990,795	260,554
2	162,831	145,121	1369,056	253,440
3	271,536	164,554	892,792	245,317
4	162,582	145,063	1541,132	255,690
5	381,490	177,473	1534,241	255,605
6	306,603	169,169	3656,106	272,103
7	164,045	145,403	2328,743	263,533
8	340,359	173,138	2339,057	263,617
9	179,891	148,907	686,042	240,312
10	294,079	167,584	2735,985	266,595

Tabel 4.10 menunjukkan bahwa pada data *training* dan data *testing* diperoleh model FFNN optimum 8 neuron di *hidden layer* pada replikasi 4. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.17.



Gambar 4.17 Arsitektur Jaringan FFNN 8 Neuron

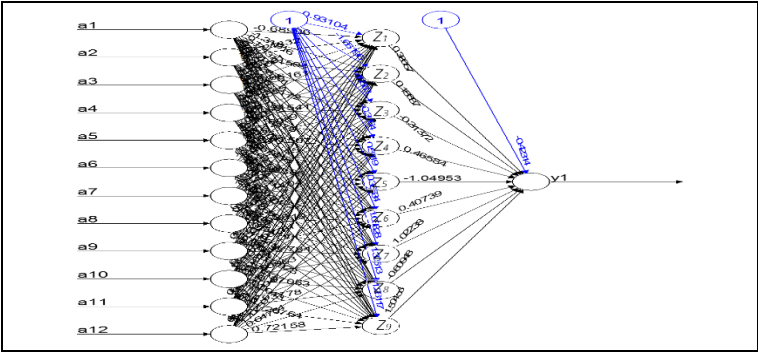
9. Neuron 9

Uji kebaikan model sebanyak 9 neuron *hidden layer* disajikan pada Tabel 4.11.

Tabel 4.11 Uji Kebaikan Model dengan Neuron 9

Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
1	306,198	197,119	1569,773	284,040
2	196,696	180,301	1662,087	285,125
3	258,597	190,698	2309,973	291,379
4	190,678	179,120	1490,405	283,054
5	221,872	184,878	698,068	268,643
6	305,107	196,983	3425,449	298,865
7	214,380	183,572	506,168	262,535
8	466,528	213,120	1272,205	280,046
9	333,060	200,314	3181,078	297,459
10	252,229	189,751	1819,513	286,845

Tabel 4.11 menunjukkan bahwa pada data *training* dan data *testing* diperoleh model FFNN optimum 9 neuron di *hidden layer* pada replikasi 4. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.18.




Gambar 4.18 Arsitektur Jaringan FFNN 9 Neuron

10. Neuron 10
Uji kebaikan model sebanyak 10 neuron *hidden layer* disajikan pada Tabel 4.12.

Tabel 4.12 Uji Kebaikan Model dengan Neuron 10

Replikasi	Training		Testing	
	MSE	AIC	MSE	AIC
1	316,570	226,385	4721,965	332,964
2	285,622	222,475	621,293	294,429
3	197,623	208,480	1386,969	309,687
4	283,993	222,258	1564,399	311,974
5	251,408	217,627	418,923	286,941
6	262,774	219,307	747,659	297,947
7	312,110	225,845	2873,143	323,525
8	426,669	237,726	7581,358	341,960
9	250,252	217,452	2142,939	317,953
10	279,804	221,693	1609,950	312,520

Tabel 4.12 menunjukkan bahwa pada data *training* dan data *testing* diperoleh model FFNN optimum 10 neuron di *hidden layer* pada replikasi 3. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.19.



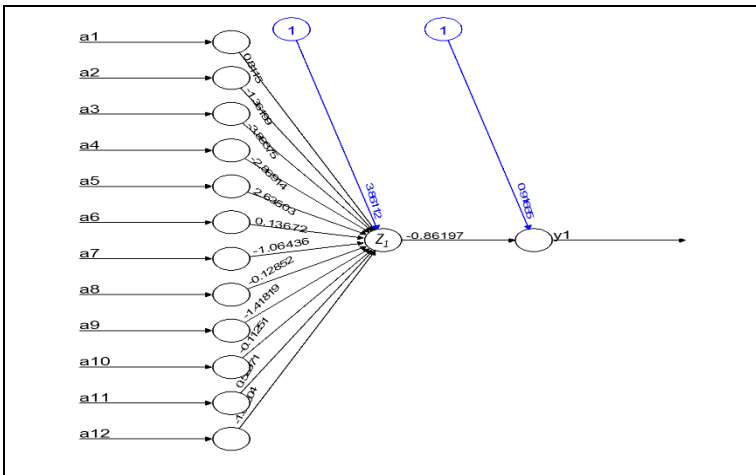
Gambar 4.19 Arsitektur Jaringan FFNN 10 Neuron

Pemilihan model terbaik pada data *training* dan *testing* menggunakan nilai MSE dan AIC yang disajikan pada Tabel 4.13.

Tabel 4.13 Pemilihan Model Terbaik pada Data *Training* dan *Testing*

Hidden Layer	Training		Testing	
	MSE	AIC	MSE	AIC
Neuron 1	120,998	-62,163	513,771	38,818
Neuron 2	198,646	-15,324	2117,561	93,727
Neuron 3	123,853	-5,276	684,135	82,154
Neuron 4	139,641	27,283	425,178	119,222
Neuron 5	177,845	64,473	1381,478	169,612
Neuron 6	150,606	86,155	3089,860	212,906
Neuron 7	175,260	119,916	1950,468	232,165
Neuron 8	162,582	145,063	1541,132	255,690
Neuron 9	190,678	179,120	1490,405	283,054
Neuron 10	197,623	208,480	1386,969	309,687

Tabel 4.13 menunjukkan bahwa pada data *training* diperoleh model FFNN optimum sebanyak 1 neuron di *hidden layer*, dan pada data *testing* diperoleh model optimum sebanyak 4 neuron di *hidden layer* berdasarkan nilai MSE sedangkan nilai AIC sebanyak 1 neuron. Model FFNN yang digunakan pada penelitian ini berdasarkan nilai AIC, karena nilai AIC memperhatikan parameter disetiap *hidden layer* dan digunakan untuk membentuk model data *training*. Arsitektur jaringan FFNN yang terbentuk dari model terbaik FFNN disajikan pada Gambar 4.20.



Gambar 4.20 Arsitektur Jaringan FFNN Terbaik


Berdasarkan Gambar 4.20, diperoleh hasil perhitungan pada *hidden layer* (z_i). Model FFNN di *hidden layer* sebanyak 1 neuron adalah sebagai berikut.

$$z_1 = \frac{1}{1 + e^{-(3,861 + 0,811x_1 - 1,362x_{1(t-1)} - \dots - 1,015x_{6(t-1)})}}$$

dan model FFNN *output layer* pada pendapatan asli daerah adalah sebagai berikut.

$$y = \frac{1}{1 + e^{-(0,917 - 0,862z_1)}}$$

Perbandingan data aktual dengan data ramalan *training* dan *testing* disajikan pada Gambar 4.21 (a) dan 4.21 (b). Gambar 4.21 (a) dan 4.21 (b) menunjukkan bahwa terdapat konsistensi jika nilai MSE dan nilai AIC paling kecil yang digunakan maka plot hasil ramalan juga cenderung mengikuti data pengamatan.



Gambar 4.21 Perbandingan Data Aktual dengan Data Ramalan
(a) Data Training dan (b) Data Testing

4.3.2 Peramalan Data Pendapatan Asli Daerah

Setelah melakukan pemilihan kriteria kebaikan model, selanjutnya melakukan peramalan pada data pendapatan asli daerah untuk periode satu tahun ke depan menggunakan model FFNN di *hidden layer* sebanyak 1 neuron disajikan pada Tabel 4.14.

Tabel 4.14 Peramalan Data Pendapatan Asli Daerah dengan FFNN

Kabupaten/Kota	Ramalan	Kabupaten/Kota	Ramalan
Kep. Mentawai	58,611	Kab. Darmasraya	70,547
Kab. Pesisir Selatan	63,409	Kab. Pasaman Barat	85,460
Kab. Solok	70,456	Kota Padang	408,042
Kab. Sijunjung	62,035	Kota Solok	59,914
Kab. Tanah Datar	72,805	Kota Sawahlunto	57,325
Kab. Padang Pariaman	77,730	Kota Padang Panjang	61,510
Kab. Agam	92,182	Kota Bukittinggi	96,365
Kab Lima Puluh Kota	75,434	Kota Payakumbuh	64,273
Kab. Pasaman	66,089	Kota Pariaman	63,221
Kab. Solok Selatan	59,032		

Berdasarkan hasil ramalan terhadap data jumlah pendapatan asli daerah di Provinsi Sumatera Barat untuk periode satu tahun kedepan pada Tabel 4.14 terlihat bahwa terjadi peningkatan dan penurunan jumlah pendapatan asli daerah pada kabupaten/kota tertentu. Kabupaten/kota yang memiliki pendapatan asli daerah meningkat adalah Kep. Mentawai, Kab. Solok, Kab. Sijunjung, Kab. Padang Pariaman, Kab. Agam, Kab. Lima Puluh Kota, Kab. Pasaman, Kab. Solok Selatan, Kab. Darmasraya, Kab. Pasaman Barat, Kota Solok, Kota Sawahlunto, Kota Padang Panjang, dan Kota Bukittinggi. Sedangkan lima kabupaten/kota lainnya memiliki pendapatan asli daerah yang turun dari tahun sebelumnya.

BAB V

KESIMPULAN DAN SARAN

Setelah analisis dan pembahasan dilakukan, didapatkan beberapa hal yang dapat disimpulkan mengenai pendapatan asli daerah di Provinsi Sumatera Barat tahun 2015 dan faktor-faktor yang diduga mempengaruhinya yang menjawab dari tujuan penelitian ini. Selain itu, juga terdapat beberapa hal yang dapat disarankan bagi penelitian selanjutnya maupun dengan topik terkait.

5.1 Kesimpulan

Kesimpulan yang dapat diambil dari penelitian adalah sebagai berikut.

1. Jumlah pendapatan asli daerah tertinggi terdapat di Kota Padang sebesar Rp. 451,1 milyar dan terendah terdapat di Kota Pariaman sebesar Rp. 23,6 milyar. Kabupaten/kota dengan jumlah pengeluaran pemerintah tertinggi terdapat di Kota Padang sebesar Rp. 1948,4 milyar dan terendah terdapat di Kota Solok sebesar Rp. 483,6 milyar. Kabupaten/kota dengan PDRB tertinggi terdapat di Kota Padang sebesar Rp. 35198 milyar dan yang terendah terdapat di Kota Padang Panjang sebesar Rp. 2066 milyar. Kabupaten/kota dengan jumlah penduduk tertinggi terdapat di Kota Padang sebesar 902,4 ribu orang dan terendah terdapat di Kota Padang Panjang sebesar 50,9 ribu orang. Kabupaten/kota dengan jumlah perusahaan tertinggi terdapat di Kota Padang sebesar 1029 perusahaan dan terendah terdapat di Kabupaten Kepulauan Mentawai sebesar 95 perusahaan. Kabupaten/kota dengan jumlah hotel tertinggi terdapat di Kota Padang sebesar 93 hotel dan terendah terdapat di Kota Sawahlunto sebesar 2 hotel. Kabupaten/kota dengan jumlah pelanggan listrik tertinggi terdapat di Kota Padang sebesar 230,9 ribu pelanggan dan terendah terdapat di Kabupaten Kepulauan Mentawai sebesar 6,3 ribu pelanggan.
2. Data pendapatan asli daerah di Provinsi Sumatera Barat dapat dimodelkan dengan metode *Feed Forward Neural Networks*

(FFNN). Model yang optimum di *hidden layer* sebanyak 1 *neuron*, dengan model terbentuk adalah FFNN (12,1,1).

5.2 Saran

Dari kesimpulan yang diperoleh, maka terdapat beberapa hal yang dapat disarankan. Bagi peneliti selanjutnya agar menambahkan variabel independen lain yang diduga mempengaruhi jumlah pendapatan asli daerah di Provinsi Sumatera Barat dengan menggunakan data terbaru, dan sebaiknya menggunakan model lain yang dapat merangkum pengaruh variabel-variabel lain yang mempengaruhi pendapatan asli daerah di Provinsi Sumatera Barat.

DAFTAR PUSTAKA

- Adinugraha, T. A. (2016). Prediksi Jumlah Pendapatan Asli Daerah Kabupaten Boyolali Dengan Metode Jaringan Syaraf Tiruan Backpropagation. Malang: Tugas Universitas Islam Negeri Maulana Malik Ibrahim.
- Atmaja, A. E. (2010). Analisis Faktor-Faktor Yang Mempengaruhi Pendapatan Asli Daerah (PAD) di Kota Semarang. Semarang: Universitas Negeri Semarang
- Dodge, Y. (2003) *The Oxford Dictionary of Statistical Terms*, OUP. ISBN 0-19-920613-9
- Fithriasari, K., Iriawan, N., Ulama, B. S. S. & Sutikno. (2013). On The Multivariate Time Series Rainfall Modeling Using TDNN. *Internasional Journal of Applied Mathematics and Statistics*TM, 44(14), 193-201.
- Halim, A. (2004). Akutansi Keuangan Daerah. Jakarta: Salemba Empat
- Muchtolifah. (2010). Analisis Beberapa Faktor yang Mempengaruhi Pendapatan Asli Daerah (PAD) di Kota Surabaya. Jurnal Ilmu Ekonomi Pembangunan Vol. 1 No. 2.
- Prameswari, W. C. (2016). Pemodelan Produksi Minyak dan Gas Bumi Pada Platform "MK" di PT X Menggunakan Metode ARIMA, Neural Network, dan Hibrida ARIMA-Neural Network. Surabaya: Tugas Akhir Institut Teknologi Sepuluh Nopember.
- Puspitaningrum, D. (2006). Pengantar Jarian Saraf Tiruan. Yogyakarta: ANDI
- Setiawan, K. (2003). Paradigma Sistem Cerdas. Malang: Bayumedia Publishing.
- Sholeh dan Rochmansjah. (2010). Pengelolaan Keuangan dan Asset Daerah. Bandung: Fokus Media.
- Suhartono. (2007). Feed Forward Neural Network untuk Pemodelan Runtun Waktu. Yogyakarta: Universitas Gadjah Mada.

- Susanto, Y. (2016). Peramalan Curah Hujan dengan Pendekatan Model ARIMA, Feed Forward Neural Network dan Hybrid (ARIMA-NN). Surabaya: Tugas Akhir Institut Teknologi Sepuluh Nopember.
- T. Teraesvirta, C. F. Lin, dan C. W. J. Granger. (1993). *Power of the Neural Network Linearity Test. Journal of Time Series Analysis* 14, 209-220.
- Wei, W, W, S. (2006). *Time Series Analysis: Univariate and Multivariat Methods (2nd ed.)*. New York: Addison Wesley.

LAMPIRAN

Lampiran 1. Data Penelitian

Tahun	Kabupaten/Kota	Y (Rp. Milyar)	X ₁ (Rp. Milyar)	X ₂ (Rp. Milyar)
2012	Kep. Mentawai	32,710	515,944	589,972
	Kab. Pesisir Selatan	36,323	859,367	2349,436
	Kab. Solok	23,153	743,201	2448,011
	Kab. Sijunjung	32,540	546,754	1506,681
	Kab. Tanah Datar	48,778	730,081	2924,847
	Kab. Padang Pariaman	40,097	813,804	3233,680
	Kab. Agam	37,003	832,728	3503,882
	Kab. Lima Puluh Kota	22,634	766,393	3218,673
	Kab. Pasaman	25,544	592,258	1541,989
	Kab. Solok Selatan	22,756	487,390	739,663
	Kab. Darmasraya	45,199	544,860	1316,136
	Kab. Pasaman Barat	33,702	659,236	3067,381
	Kota Padang	202,965	1400,212	13637,509
	Kota Solok	26,267	397,860	594,698
	Kota Sawahlunto	34,890	373,246	582,969
	Kota Padang Panjang	32,550	350,109	474,561
	Kota Bukittinggi	49,188	447,443	1163,127
	Kota Payakumbuh	50,021	468,917	994,371
	Kota Pariaman	15,096	399,440	810,844
⋮	⋮	⋮	⋮	⋮
2015	Kep. Mentawai	47,820	840,152	2482,666
	Kab. Pesisir Selatan	91,085	1360,363	7816,444
	Kab. Solok	46,468	1060,453	8081,727
	Kab. Sijunjung	53,527	746,621	5535,887
	Kab. Tanah Datar	97,334	1106,619	7953,043

Lampiran 1. Data Penelitian (Lanjutan)

Tahun	Kabupaten/Kota	Y (Rp. Milyar)	X ₁ (Rp. Milyar)	X ₂ (Rp. Milyar)
2015	Kab. Padang Pariaman	63,239	1151,573	11084,501
	Kab. Agam	75,049	1246,935	11908,402
	Kab. Lima Puluh Kota	55,265	1076,182	9120,479
	Kab. Pasaman	58,048	862,664	5084,627
	Kab. Solok Selatan	34,508	701,304	3267,782
	Kab. Darmasraya	66,456	800,462	6159,600
	Kab. Pasaman Barat	70,243	909,875	9357,388
	Kota Padang	451,050	1948,374	35197,850
	Kota Solok	28,259	483,569	2306,783
	Kota Sawahlunto	52,971	539,531	2249,595
	Kota Padang Panjang	47,351	490,320	2065,997
	Kota Bukittinggi	62,662	574,638	4872,533
	Kota Payakumbuh	69,930	694,422	3551,029
	Kota Pariaman	23,647	581,026	2900,336

Lampiran 1. Data Penelitian (Lanjutan)

Tahun	Kabupaten/Kota	X ₃ (Rp. Ribu)	X ₄ (Buah)	X ₅ (Buah)	X ₆ (Ribu/orang)
2012	Kep. Mentawai	78,511	46	7	4,536
	Kab. Pesisir Selatan	437,638	377	16	71,662
	Kab. Solok	355,077	283	5	54,291
	Kab. Sijunjung	207,474	291	9	25,058
	Kab. Tanah Datar	342,991	232	8	53,891
	Kab. Padang Pariaman	396,883	94	1	59,420
	Kab. Agam	463,719	386	33	86,400
	Kab. Lima Puluh Kota	355,928	331	2	42,305
	Kab. Pasaman	258,929	248	16	34,474
	Kab. Solok Selatan	263,838	440	16	36,527

Lampiran 1. Data Penelitian (Lanjutan)

Tahun	Kabupaten/Kota	X ₃ (Rp. Ribu)	X ₄ (Buah)	X ₅ (Buah)	X ₆ (Ribu orang)
2012	Kab. Darmasraya	198,614	538	10	46,766
	Kab. Pasaman Barat	376,548	787	14	50,705
	Kota Padang	854,336	1048	70	196,663
	Kota Solok	61,152	540	5	27,139
	Kota Sawahlunto	58,068	104	2	10,654
	Kota Padang Panjang	48,187	184	14	31,940
	Kota Bukittinggi	114,415	568	60	43,060
	Kota Payakumbuh	119,942	488	11	53,781
	Kota Pariaman	80,870	330	9	44,627
⋮	⋮	⋮	⋮	⋮	⋮
2015	Kep. Mentawai	85,295	95	12	6,291
	Kab. Pesisir Selatan	450,186	163	17	87,584
	Kab. Solok	363,684	385	7	65,053
	Kab. Sijunjung	222,512	460	13	30,620
	Kab. Tanah Datar	344,828	407	11	60,577
	Kab. Padang Pariaman	406,076	230	6	67,701
	Kab. Agam	476,881	306	26	99,177
	Kab. Lima Puluh Kota	368,985	277	16	49,032
	Kab. Pasaman	269,883	443	14	40,697
	Kab. Solok Selatan	159,796	137	12	31,936
	Kab. Darmasraya	223,112	356	11	57,946
	Kab. Pasaman Barat	410,307	617	17	72,836
	Kota Padang	902,413	1029	93	230,944
	Kota Solok	66,106	190	6	31,812
	Kota Sawahlunto	60,186	98	2	12,019
	Kota Padang Panjang	50,883	123	20	36,349
	Kota Bukittinggi	122,621	218	66	49,828
	Kota Payakumbuh	127,826	272	11	63,450
	Kota Pariaman	84,709	248	11	49,975

Lampiran 2. Syntax FFNN data *Training* dengan 1 neuron di *Hidden Layer*

```
library(neuralnet)
data=read.csv("dataaaa.txt")
training=data[1:38,]
testing=data[-(1:38),]
n.training=38
n.testing=19
#neuron di hidden
h=1

#insample
y=training[,1]
x1=training[,2]
x2=training[,3]
x3=training[,4]
x4=training[,5]
x5=training[,6]
x6=training[,7]
x7=training[,8]
x8=training[,9]
x9=training[,10]
x10=training[,11]
x11=training[,12]
x12=training[,13]

w=cbind(y,x1,x2,x3,x4,x5,x6,x7,x8,x9,x10,x11,x12)
#normalized
y1=(y-min(y))/(max(y)-min(y))
a1=(x1-min(x1))/(max(x1)-min(x1))
a2=(x2-min(x2))/(max(x2)-min(x2))
a3=(x3-min(x3))/(max(x3)-min(x3))
a4=(x4-min(x4))/(max(x4)-min(x4))
a5=(x5-min(x5))/(max(x5)-min(x5))
a6=(x6-min(x6))/(max(x6)-min(x6))
a7=(x7-min(x7))/(max(x7)-min(x7))
a8=(x8-min(x8))/(max(x8)-min(x8))
a9=(x9-min(x9))/(max(x9)-min(x9))
a10=(x10-min(x10))/(max(x10)-min(x10))
```

```

a11=(x11-min(x11))/(max(x11)-min(x11))
a12=(x12-min(x12))/(max(x12)-min(x12))

v=cbind(y1,a1,a2,a3,a4,a5,a6,a7,a8,a9,a10,a11,a12)
variabel=(v-min(v))/(max(v)-min(v))
net=neuralnet(y1~a1+a2+a3+a4+a5+a6+a7+a8+a9+a10+a11+a12,
              variabel, hidden=h, threshold=0.05,stepmax = 10000,
              learningrate.factor=list(minus=0.5,plus=1.2),
              algorithm="slr",err.fct="sse", act.fct="logistic",
              linear.output=TRUE)
covariat=cbind(a1,a2,a3,a4,a5,a6,a7,a8,a9,a10,a11,a12)
fits=compute(net, covariat)
fits=fits$net.result
fits1=(fits)*(max(y)-min(y))+min(y)
fits1
mse.in=mean((y-fits1)^2, na.rm=T)
mse.in
sse.in=mse.in/(n.training-2)
sse.in

```

Lampiran 3. Syntax FFNN Data *Testing* dengan 1 neuron di *Hidden Layer*

```

#outsample
y1=testing[,1]
x1=testing[,2]
x2=testing[,3]
x3=testing[,4]
x4=testing[,5]
x5=testing[,6]
x6=testing[,7]
x7=testing[,8]
x8=testing[,9]
x9=testing[,10]
x10=testing[,11]
x11=testing[,12]
x12=testing[,13]

b1=(x1-min(x1))/(max(x1)-min(x1))

```

```

b2=(x2-min(x2))/(max(x2)-min(x2))
b3=(x3-min(x3))/(max(x3)-min(x3))
b4=(x4-min(x4))/(max(x4)-min(x4))
b5=(x5-min(x5))/(max(x5)-min(x5))
b6=(x6-min(x6))/(max(x6)-min(x6))
b7=(x7-min(x7))/(max(x7)-min(x7))
b8=(x8-min(x8))/(max(x8)-min(x8))
b9=(x9-min(x9))/(max(x9)-min(x9))
b10=(x10-min(x10))/(max(x10)-min(x10))
b11=(x11-min(x11))/(max(x11)-min(x11))
b12=(x12-min(x12))/(max(x12)-min(x12))

covariatout=cbind(b1,b2,b3,b4,b5,b6,b7,b8,b9,b10,b11,b12)
fits=compute(net, covariatout)
fits=fits$net.result
fits1=(fits)*(max(y1)-min(y1))+min(y1)
fits1
mse.out=mean((y1-fits1)^2, na.rm=T)
sse.out=mse.out/(n.testing-2)
plot(net)

```

Lampiran 4. Uji Kebaikan Model NN

<i>Hidden Layer</i>	MSE		AIC	
	<i>Training</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>
Neuron 1	120.998	-62.163	-62.163	513.771
Neuron 2	198.646	-15.324	-15.324	2117.561
Neuron 3	123.853	-5.276	-5.276	684.135
Neuron 4	139.641	27.283	27.283	425.178
Neuron 5	177.845	64.473	64.473	1381.478
Neuron 6	150.606	86.155	86.155	3089.860
Neuron 7	175.260	119.916	119.916	1950.468
Neuron 8	162.582	145.063	145.063	1541.132
Neuron 9	190.678	179.120	179.120	1490.405
Neuron 10	197.623	208.480	208.480	1386.969

Lampiran 5. Estimasi Parameter Metode NN dengan 1 neuron di *hidden layer*

- a. Estimasi parameter pada *output layer* (lapisan keluaran)

<i>Output</i>	<i>Y</i>
Bias	0,917
z_1	-0,862

- b. Estimasi parameter pada *hidden layer* (lapisan tersembunyi)

<i>Input</i>	z_1
Bias	3,861
X_1	0,811
$X_{1(t-1)}$	-1,362
X_2	-3,894
$X_{2(t-1)}$	-2,869
X_3	2,635
$X_{3(t-1)}$	0,137
X_4	-1,064
$X_{4(t-1)}$	-0,128
X_5	-1,418
$X_{5(t-1)}$	-0,112
X_6	0,530
$X_{6(t-1)}$	-1,015

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Penulis yang bernama Reni Zuherlina biasa dipanggil Reni lahir di Solok pada tanggal 24 Juni 1993 sebagai anak pertama dari tiga bersaudara. Penulis bertempat tinggal di Jalan Sikumbang No. 41 Dadok Tunggul Hitam Kec. Koto Tangah Kota Padang, Sumatera Barat. Penulis telah menempuh pendidikan formal dimulai dari TK Islam Bakti 2, SD Negeri 20 Dadok Tunggul Hitam, MTsN Model Padang, dan SMA Negeri 10 Padang. Setelah lulus dari SMA, penulis melanjutkan studinya di Diploma III Jurusan Matematika FMIPA UNP Padang melalui jalur penerimaan Reguler pada tahun 2011. Kemudian pada tahun 2015, penulis lanjut studi lagi di S1-Lintas Jalur Departemen Statistika FMIPA ITS. Penulis mendapatkan kesempatan Kerja Praktek di BPS Kota Padang. Untuk kritik dan saran dapat dikirim melalui email penulis renizuherlina@gmail.com.